

SVEUČILIŠTE U RIJECI  
POMORSKI FAKULTET U RIJECI

Miroslav Bistrović

**PRILOG POVEĆANJU UČINKOVITOSTI  
BRODSKOGA VATRODOJAVNOG  
SUSTAVA PRIMJENOM NOVIH  
ELEKTRONIČKIH I RAČUNALNIH  
TEHNOLOGIJA**

DOKTORSKA DISERTACIJA

Rijeka, 2016.

SVEUČILIŠTE U RIJECI  
POMORSKI FAKULTET U RIJECI

Miroslav Bistrović

**PRILOG POVEĆANJU UČINKOVITOSTI  
BRODSKOGA VATRODOJAVNOG  
SUSTAVA PRIMJENOM NOVIH  
ELEKTRONIČKIH I RAČUNALNIH  
TEHNOLOGIJA**

DOKTORSKI DISERTACIJA

Mentor: Prof. dr. sc. Vinko Tomas

Rijeka, 2016.

UNIVERSITY OF RIJEKA  
FACULTY OF MARITIME STUDIES IN RIJEKA

Miroslav Bistrović

**A CONTRIBUTION TO INCREASING THE  
EFFICIENCY OF THE SHIP FIRE  
DETECTION SYSTEM BY  
IMPLEMENTING NEW ELECTRONIC  
AND COMPUTER TECHNOLOGIES**

DOCTORAL THESIS

Rijeka, 2016.

Mentor rada: Prof. dr. sc. Vinko Tomas

Doktorska disertacija obranjena je dana 20.07.2016. na Pomorskom fakultetu Sveučilišta u Rijeci, pred povjerenstvom u sastavu:

1. Prof. dr. sc. Serđo Kos, predsjednik  
(Pomorski fakultet u Rijeci)
2. Prof. dr. sc. Vinko Tomas, mentor i član  
(Pomorski fakultet u Rijeci)
3. Prof. dr. sc. Dragan Čišić, član  
(Pomorski fakultet u Rijeci)
4. Prof. dr. sc. Dragan Martinović, član  
(Pomorski fakultet u Rijeci)
5. Prof. dr. sc. Danko Kezić, član  
(Pomorski fakultet u Splitu)

---

**ZAHVALA**

*Ovom doktorskom disertacijom zaokružuje se jedno lijepo i intenzivno razdoblje u mom životu. Zahvala za pomoć u izradi ovog rada i svemu onom što je njemu prethodilo ide mnogim osobama. Iskrene zahvale prof. dr. sc. Vinku Tomasu, mojem mentoru, na ukazanom povjerenju, strpljenju i prenesenom znanju kroz sve godine mojeg dodiplomskog i doktorskog studija.*

*Zahvaljujem predsjedniku povjerenstva za ocjenu i obranu prof. dr. sc. Serđu Kosu te članovima povjerenstva za ocjenu teme i doktorske disertacije prof. dr. sc. Draganu Čišiću, prof. dr. sc. Draganu Martinoviću i prof. dr. sc. Danku Keziću na dobronamjernim primjedbama i sugestijama.*

*Zahvalio bih se mojim roditeljima i članovima uže obitelji za ljubav i povjerenje koje su imali u mene.*

*Na kraju, najveće hvala mojoj supruzi Gabrieli na njezinoj bezgraničnoj potpori, pomoći, razumijevanju i ljubavi koju mi je pružala tijekom izrade ove disertacije.*

*U Rijeci, srpanj 2016.*

*Miroslav Bistrović*

---

## SAŽETAK

Doktorska disertacija – Prilog povećanju učinkovitosti broetskoga vatrodojavnog sustava primjenom novih elektroničkih i računalnih tehnologija – proučava pristup za poboljšanje sigurnosti broda od požara. Tradicionalni način zaštite od požara podrazumijeva tri područja: strukturnu zaštitu od požara, otkrivanje i gašenje požara. Više od polovice brodskih požara dogodi se u prostoru brodske strojarnice, zbog čega se naglasak istraživanja usmjerio upravo u to područje. Štete i gubitci nastali uslijed požara na brodovima zadnjih desetljeća ubrzali su razvoj novih tehnika, tehnologija i inovacija s ciljem povećanja sigurnosti i pouzdanosti sustava detekcije požara. Rano otkrivanje požara ima presudnu ulogu u njegovu gašenju i sprječavanju širenja. Razvoj vatrodojavne tehnologije potaknut je nizom požarnih incidenata, koji su za posljedicu imali velike materijalne gubitke, uz još veće ljudske žrtve. Dosadašnjim razvojem detektora dojave požara integracijom tehnologija dojave požara s mikroelektroničkim i informacijskim tehnologijama ostvaren je visok stupanj autonomnosti sustava, uz istodobno povećanje pouzdanosti i raspoloživost. Istovremeno, povećanjem potražnje za poboljšanom tehnologijom ranog detektiranja požara i njegovog sprječavanja, razvijaju se napredni sustavi detekcije čiji upravljački algoritmi imaju zadatak inteligentne obrade raspoznavanja stvarnog od lažnog signala dima ili plamena. Koristeći uslugu koju nudi nova tehnologija, brodaru je cilj kvalitetnija zaštita posade, broetskog inventara te smanjenje troškova koji bi mogli nastati uslijed nesreće izazvane požarom. Uz pregled najnovije tehnike i tehnologije ranog otkrivanja požara na brodovima, ova doktorska disertacija prikazuje poboljšanje karakteristika novih sustava i komponenti sustava detekcije, analizirajući njihove mogućnosti, prednosti i primjenu.

Rezultati istraživanja pokazali su da se primjenom broetskoga vatrodojavnog sustava temeljenog na računalnom vidu može unaprijediti dosadašnji klasični brodski vatrodojavni sustav, postizanjem veće brzine otkrivanja požarnog incidenta, a samim time i bržom intervencijom gašenja i suzbijanja njegovog daljnjeg širenja.

**Ključne riječi:** požar, brod, tehnika, tehnologija, modeliranje, računalni vid, videodetekcija dima.

## SUMMARY

Doctoral thesis – A contribution to increasing the efficiency of the Ship fire detection system by implementing new electronic and computer technologies – examines an approach to the increasing ship's safety in a case of fire. The traditional way of fire protection involves three areas: structural fire protection, fire detection and fire fighting. More than half of a ship's fires occur in the area of the ship's engine room, which is why the emphasis of the research is focused precisely in this area. Damage and losses incurred due to fire on ships in recent decades have accelerated the development of new techniques, technologies and innovations to increase the safety and reliability of fire detection systems. Early detection plays a crucial role in fire fighting and prevention of fire spreading. The development of fire alarm technology has been driven by a number of fire incidents which have caused huge material losses, with an even greater human toll. The current development of fire alarm detectors with the integration of technology of fire detection system with micro-electronic and information technology has created a high degree of system autonomy, while increasing reliability and availability. At the same time, the increasing demand for improved technology of early detection of fire and its prevention has developed advanced detection systems whose control algorithms have the task of intelligent processing, distinguishing real from false signals of smoke or flames. Through usage of a service offered by the new technology, the ship operator aims to gain quality crew protection, and the protection of the ship's inventory, as well as reduction of expenses that could appear due to an accident caused by a fire. With an overview of the latest techniques and technologies for early detection of fires on ships, this doctoral thesis shows the improvement of the characteristics of new systems and components of detection systems, analyzing their features, advantages and applications.

The results of a research has shown that an implementation of a computer vision based fire detection can improve current classical fire detection system, by reaching greater speed of fire detection, thus faster fire containment and fire suppression.

**Keywords:** fire, ship, technique, technology, modeling, computer vision, video-based smoke detection.

---

# Sadržaj

SAŽETAK.....	VI
SUMMARY .....	VII
Sadržaj .....	1
1. UVOD.....	1
1.1. Problem, predmet i objekt istraživanja .....	2
1.2. Znanstvena hipoteza i pomoćne hipoteze .....	5
1.3. Svrha i ciljevi istraživanja .....	6
1.4. Pregled dosadašnjih istraživanja .....	6
1.5. Znanstvene metode .....	11
1.6. Struktura doktorske disertacije .....	11
2. KARAKTERISTIKE BRODSKIH VATRODOJAVNIH ALARMNIH SUSTAVA.....	14
2.1. Detektori alarmnog vatrodojavnog sustava .....	15
2.1.1. Klasifikacija detektora .....	15
2.1.1.1. Temperaturni detektori .....	16
2.1.1.1.1. Fiksni temperaturni detektori .....	18
2.1.1.1.2. Termodiferencijalni temperaturni detektori .....	22
2.1.1.1.3. Pneumatski temperaturni detektori .....	23
2.1.1.2. Detektori dima .....	23
2.1.1.2.1. Ionizirajući detektor dima .....	25
2.1.1.2.2. Optički detektor dima .....	27
2.1.1.2.3. Laserski detektor dima .....	29
2.1.1.3. Detektori plamena .....	29
2.1.1.3.1. UV detektor plamena .....	31
2.1.1.3.2. IR detektor plamena .....	32
2.1.1.3.3. UV/IR detektor plamena .....	34



2.1.1.4.	Ručni javljači .....	35
2.1.2.	Optimizacija rasporeda detektora vatrodojavnog sustava .....	36
2.1.3.	Grupiranje detektora vatrodojavnog sustava u zone .....	38
2.2.	Osnovne karakteristike i vrste vatrodojavnih alarmnih sustava .....	39
2.2.1.	Konvencionalni vatrodojavni alarmni sustav.....	39
2.2.2.	Analogni vatrodojavni alarmni sustav .....	41
2.2.3.	Analogno adresabilni alarmni sustav .....	42
2.2.4.	Vatrodojavni sustav zasnovan na upotrebi svjetlovodnog kabela ...	43
2.2.5.	Bežični vatrodojavni sustav .....	45
2.3.	Struktura broorskoga vatrodojavnog sustava .....	46
2.4.	Osnovne funkcije broorskoga alarmnog vatrodojavnog sustava .....	47
2.5.	Pouzdanost i raspoloživost broorskoga alarmnog vatrodojavnog sustava ...	48
2.5.1.	Pouzdanost broorskoga vatrodojavnog sustava.....	48
2.5.1.1.	Povećanje pouzdanosti broorskoga vatrodojavnog sustava kod putničkih brodova metodom redundancije .....	50
2.5.1.2.	Pouzdanost sistema napajanja za broski vatrodojavni sustav .....	51
2.5.2.	Raspoloživost broorskoga vatrodojavnog sustava .....	51
3.	UZROCI NASTANKA I KARAKTERISTIKE BRORSKIH POŽARA .....	57
3.1.	Utjecajni čimbenici za razvitak požara u broskoj strojarnici .....	58
3.1.1.	Uzroci požara u strojarnici .....	60
3.1.2.	Čimbenici požara u strojarnici .....	61
3.1.3.	Izvori paljenja .....	63
3.1.3.1.	Zagrijane površine .....	64
3.1.3.2.	Otvoreni plamen .....	65
3.1.3.3.	Kemijski izvori .....	65
3.1.3.4.	Iskre mehaničkog podrijetla .....	65
3.1.3.5.	Iskre električnog podrijetla .....	66
3.2.	Faze razvoja i prijenos požara na brodu .....	67
3.2.1.	Faze razvoja požara .....	67
3.2.1.1.	Faza nastajanja požara .....	68

3.2.1.2.	Rana faza razvoja požara .....	72
3.2.1.3.	Faza potpuno razvijenog požara .....	73
3.2.1.4.	Razdoblje slabljenja požara .....	74
3.3.	Analiza požara u brodskim strojarnicama.....	76
<b>4.</b>	<b>NOVE ELEKTRONIČKE I RAČUNALNE TEHNOLOGIJE U BRODSKIM VATRODOJAVNIM SUSTAVIMA .....</b>	<b>80</b>
4.1.	Značaj Solas propisa II-1/8-1, II-2/22 na razvitak tehnologije vatrodjave.....	80
4.2.	Integracija sustava dojave požara u brodski integrirani sustav .....	82
4.3.	Primjena višekriterijske tehnologije u otkrivanju požara .....	84
4.4.	Utjecaj nanotehnologije na razvoj vatrodjave .....	86
4.5.	Upotreba svjetlovodnog kabela u sustavima vatrodjave .....	88
4.6.	Uvođenje robotike u otkrivanju dima i plamena .....	90
4.7.	Korištenje termovizije za rano otkrivanje potencijalnog žarišta požara .....	92
4.8.	Primjena računalne inteligencije i računalnog vida .....	98
4.8.1.	Modeliranje širenja požara u strojarnici broda .....	101
4.8.2.	Upotreba računalnog vida za detekciju plamena .....	104
4.8.3.	Upotreba računalnog vida za detekciju dima .....	107
<b>5.</b>	<b>PRIJEDLOG MODELA BROŠKOGA VATRODOJAVNOG SUSTAVA TEMELJENOG NA RAČUNALNOM VIDU .....</b>	<b>110</b>
5.1.	Primjena računalnog vida u detekciji rane faze nastanka dima i plamena.....	110
5.2.	Prijedlog modela detekcije dima temeljen na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera .....	111
5.3.	Opis modela za detekciju dima temeljenog na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera .....	114
5.3.1.	Predobrada video zapisa DCT transformacijom .....	114
5.3.2.	Statička analiza videozapisa .....	116
5.3.3.	Dinamička analiza videozapisa .....	118
5.3.4.	Odabir videoanalizatora dima i podešavanje parametara .....	121

<b>6.</b>	<b>EVALUACIJA USPJEŠNOSTI PREDLOŽENOG MODELA BRODSKOGA VATRODOJAVNOGA SUSTAVA TEMELJENOG NA RAČUNALNOM VIDU .....</b>	<b>122</b>
6.1.	Uvodna razmatranja .....	122
6.2.	Odabir i definiranje početnih uvjeta analiziranih scenarija za analizu detekcije rane faze u nastanku požara .....	123
6.2.1.	Ispitivanje detekcije dima analogno adresabilnim optičkim detektorima dima .....	124
6.2.2.	Ispitivanje detekcije dima upotrebom IP kamera.....	126
6.3.	Ispitivanje i ocjena uspješnosti predloženog modela .....	127
6.4.	Komparativna analiza klasičnog i novog predloženog pristupa u detekciji rane faze nastanka požara .....	131
6.5.	Analiza ekonomske opravdanosti predloženog modela u funkciji smanjenja ukupnih troškova uzrokovanih nepravovremenom detekcijom rane faze nastanka požara u brodskoj strojarnici .....	134
<b>7.</b>	<b>ZAKLJUČAK .....</b>	<b>136</b>
	<b>LITERATURA.....</b>	<b>139</b>
	<b>POPIS KRATICA I AKRONIMA.....</b>	<b>148</b>
	<b>POPIS OZNAKA I SIMBOLA .....</b>	<b>150</b>
	<b>POPIS SLIKA .....</b>	<b>154</b>
	<b>POPIS TABLICA.....</b>	<b>157</b>
	<b>POPIS GRAFIKONA .....</b>	<b>158</b>
	<b>Životopis.....</b>	<b>159</b>

## **1. UVOD**

Svake godine diljem svijeta od požara stradava veliki broj ljudi. Od ukupnog broja stradalih u požaru, 50 do 80 % smrtnih slučajeva uzrokovani su dimom, dok je ljudski faktor uzrok u 80 % pomorskih incidenata izazvanih požarom. Također, statistike kažu da požar i eksplozija čine  $\frac{1}{4}$  ukupnih izazvanih pomorskih incidenata. Prema statistikama DNV-a svakih 10 godina očekuje se u prosjeku 20 velikih brodskih požara nastalih u strojarnici. Izravni troškovi uzrokovani požarom u strojarnicama kreću se u rasponu od 1 do 5 milijuna dolara za teretne brodove, dok za putničke i više.

Usprkos modernoj tehnici i tehnologiji otkrivanja i pravovremenog gašenja broorskoga požara, požari predstavljaju još uvijek realno veliku opasnost. Sve veći zahtjevi današnjih brodovlasnika za smanjenjem rizika i sigurnosti plovidbe, potaknuli su proizvođače brodske opreme i znanstvenu zajednicu na istraživanje, razvoj i implementaciju novih konceptualnih rješenja. U pomorstvu strah od požara na brodu, stalno je prisutan kod pomoraca, i to od početka gradnje prvih jednostavnih drvenih brodova, čiji je materijal bio vrlo podložan požaru, pa sve do danas. Brodski požari mogu imati katastrofalne posljedice, uzrokujući velike materijalne štete, kako za brod i brodske sustave, brodski teret, gubitak ljudskih života, tako i moguću štetu za okoliš, odnosno njegov ekosustav. Zbog te činjenice vatrodojavni sustav odigrao je vrlo važnu ulogu u zaštiti ljudi i broda i to pouzdanom i brzom dojavom točne lokacije mjesta nastanka požara na brodu. Postoji direktna povezanost između visine šteta nastale požarom i vremena intervencije raznim vatrodojavnim brodskim sustavima. Proporcionalno gledano kraće vrijeme intervencije, manje su štete na brodu. Iz toga proizlazi da je osnovni zadatak vatrodojave pravovremeno reakcija, odnosno otkrivanje požarnog incidenta, radi smanjenja moguće nastale štete. Ovom problemu posvećuje se velika pozornost, što iziskuje stručan i znanstveni pristup pri projektiranju i gradnji broda, a posebno za vrijeme njegove plovidbe. SOLAS konvencija svojim pravilom definira razne zahtjeve za otkrivanje i dojavu požara, na raznim tipovima brodova, pa su ta pravila uz pravila raznih klasifikacijskih ustanova osnova za odabir i dizajniranje uređaja za dojavu požara. IMO pravila i propisi zaštite ljudskih života na moru (SOLAS konvencije) pružaju minimalnu okvirnu zaštitu od požara.

Pravilnim odabirom alarmnog sustava vatrodojave i njemu pripadajućih detektora, uz siguran rad omogućava se i sprječavanje širenja nastalog požara, pravovremena evakuacija

-----

ljudi iz ugroženog dijela broda te automatski slijed niza akcija kao što su zatvaranje protupožarnih vrata, isključivanje ventilacijskih sustava, zvučni i svjetlosni signali, uključivanje sustava za gašenje požara i slično. Današnji razvoj tehnologije i tehnike teži integraciji brodskih sustava, pri čemu i sustava vatrodojave, a samim time i boljoj kontroli nadziranja rada pojedinog sustava, što u krajnjem slučaju ima za cilj znatno jednostavnije upravljanje i nadzor.

### **1.1. Problem, predmet i objekt istraživanja**

Primjene novih tehnika i računalnih tehnologija u otkrivanju rane faze u nastanku požara na brodovima, imaju veliki utjecaj na razvoj novih sofisticiranih sustava za detekciju požara. Važno je napomenuti da je najveći problem suvremenih sustava detekcije dima i plamena, pojava lažnih alarma. Pojavu lažnih alarma za sada nije moguće u potpunosti eliminirati, iako se na tome intenzivno radi. Sam tehnološki razvoj vatrodojavnih sustava usko je povezan s tehnološkim razvojem detektora požara. Bez obzira koliko je tehnologija vatrodojave napredovala ne može se isključiti čovjek. Još uvijek, pravovremeno otkrivanje požara moguće je ljudskim poznavanjem i definiranjem uzroka i tijeka požara. Razvoj nanotehnologije i mikroelektronike omogućio je integraciju velike količine funkcija u neki novi proizvod, manjih gabarita. To se odnosi i na detektore, koji se uz pomoć mikroelektronike proizvode kao inteligentne komponente, čije se funkcije procjene i odlučivanja izvode u detektoru. Tijekom posljednjeg desetljeća, razvojem brodske automatizacije, razvijali su se i napredni sustavi za automatsko otkrivanje dima te požara na brodu, što se postiglo mnogim naprednim istraživanjima kako u komercijalne tako i u vojne svrhe, gdje prednjači mornarica SAD-a.

Od sustava za detekciju požara koji je tehnološki vrlo zahtjevan, očekuje se visoka pouzdanost i preciznost u ranom otkrivanju požarnih incidenata, što je utjecalo te potaklo znanstvenike i industriju na većinu recentnih istraživanja i razvijanje multisenzorskog pristupa, odnosno novih pametnih multisenzora. Ta su istraživanja proširena i na usavršavanje upotrebe videotehnologije u ranom otkrivanju dima i vatre, stvaranju novih pametnih algoritama, primjenu neizrazite logike u sustavima za detekciju požara, pa i samih detektora, a sve s ciljem primjene novih saznanja i rješenja za što uspješnije detektiranje vatre i dima na brodu. Upotreba neizrazite logike doprinijela je većoj točnosti donošenja ključnih odluka je li se incident dogodio ili nije, odnosno je li vatra stvarna ili lažna. Uz modeliranje, korištenjem

-----

pametnih algoritama i simulacije ponašanja požara pruža se i mogućnost modeliranja intenziteta nastalog požara u određenom prostoru na biranom modelu broda.

Jedan od bitnih faktora pri projektiranju optimalnog alarmnog sustava dojava požara je i optimizacija rasporeda detektora požara za određeni štićeni brodski prostor. U pozitivnom smislu zna se da veća gustoća postavljanja detektora povećava i brzinu reakcije sustava dojava požara, a u negativnom povećava se ukupna cijena sustava. Međutim, razni realni podaci prikupljeni prilikom eksploatacije brodova, ukazuju da broj instaliranih detektora u određenom prostoru nije bitan čimbenik efikasnosti detekcije dima ili vatre, već su to pravilni odabir vrste detektora te realni uvjeti koji vladaju određenim brodskim prostorom tijekom eksploatacije broda, kao što su veličina i visina prostora, količina kisika, strujanje zraka, temperatura okoline, količina i vrsta isparenih gorivih tekućina, kemikalija i vodenih para.

Razvojem tehnike i tehnologije, u posljednjem desetljeću došlo se do novih saznanja, a samim time i do razvoja novih sofisticiranih optičkih senzora, veće procesorske snage i visoke elektroničke pouzdanosti, što je uvelike poboljšalo i pružilo mogućnost automatskog optičkog prepoznavanja požara i u najnepovoljnijim mogućim uvjetima. Međutim, tradicionalne metode otkrivanja dima koje koriste tehnike poput uzorkovanja čestica, uzorkovanja temperature i relativne vlažnosti uzorka, imaju i nedostatke, jer senzori često moraju biti u blizini izvora dima ili plamena jer u protivnom nisu učinkoviti. Kako bi se izbjegle ove situacije razvila se videotehnologija koja koristi računalne programe za obradu i analizu videozapisa, te se tako postiže veća fleksibilnost i učinkovitost u otkrivanju dima. Na osnovi mnogih znanstvenih istraživanja razvili su se programi koji koristeći pametne algoritme, te baze podataka, stvaraju realnu podlogu za moguće korištenje videotehnologije u ranom otkrivanju dima ili plamena na brodu. Tehnologija videodetekcije dima ili plamena temelji se na analizi videosignala i daje neke osnovne smjernice što se tiče njegove primjene u sustavima vatrodjave. Računalna obrada i tehnologija analize slike danas je značajno poboljšana čime su ispunjene odgovarajuće pretpostavke za moguće primjene i u detekciji rane faze nastanka požara na brodu. Prednost videotehnologije je u tome što produkti sagorijevanja ne moraju putovati do senzora, tj. detektora, već ona pruža mogućnost otkrivanja dima ili plamena bilo gdje u određenom području, što znači da videosustav nije ograničen faktorom udaljenosti i pozicijom nastanka dima ili plamena kao što je to slučaj kod standardnih detektora. Međutim, videotehnologija ima i svoje nedostatke kao što su vezanost sustava uz ograničenja poput oštine, kontrasta i osvjetljenja u vidnom polju. Ove

-----

pretpostavke su podloga koja omogućuje daljnja istraživanja u području korištenja videozapisa u otkrivanju incidentnih požarnih situacija, odnosno otkrivanju dima ili plamena.

Uz prikupljanje realnih podataka incidenata prouzrokovanih požarom, danas računalne simulacije postaju sve češće i važnije u području istraživanja brodskih požara. One nam pomažu razumjeti i optimizirati različite vrste procesa pojave dima ili vatre te kao i doprinose razumijevanju izgaranja ovisno o vrsti medija koji je prouzrokovao incident, te materijala zahvaćenog požarom. Simulacijom požara za različite dijelove broorskog prostora pomoću programa PyroSim, SmartFire ili VisSim, sa znanstvenog stajališta doprinosi se sigurnijem i bržem automatskom otkrivanju požarnog incidenta. Standardi i računalna tehnologija uz modeliranje i simulaciju razvoja dinamičkih procesa vatre i dima nudi bolje i detaljnije razumijevanje mogućih incidentnih situacija izazvanih požarom, a samim time bolju i veću zaštitu od incidentnog događaja. U konačnici, zaštita od požara kao primjena znanosti i inženjerstva načela su za zaštitu ljudi, očuvanje okoliša, smanjenje materijalnih troškova i ekonomskih gubitaka.

U ovome radu osim pouzdanosti broorskog vatrodojavnog sustava kao jedne od presudnih značajki za sigurnost broda, tereta, posade i putnika, sustavnim pristupom u istraživanju naglasak je stavljen na primjenu novih metoda otkrivanja dima i plamena kao što je računalna obrada i analiza slike u svrhu detektiranja dima ili plamena, zatim numerička analiza rizika od požara i požarne ugroženosti broda, matematičko modeliranje dima i vatre, te razvoj različitih tehnika gašenja požara u cilju sprječavanja mogućih neželjenih posljedica. Štete nastale uslijed neadekvatnog i pogrešnog projektiranja broorskog vatrodojavnog sustava, bile direktne ili indirektna, za sigurnost broda mogu biti vrlo velike. U današnje vrijeme brodovi su konstruirani kako bi zadovoljili minimalne međunarodne sigurnosne zahtjeve, iako realnost i praksa pokazuju sasvim suprotno, odnosno neodrživost postojeće prakse. Stoga, primjena novih tehnika i računalnih tehnologija u ranom otkrivanju požara na brodovima, ima veliki utjecaj na razvoj novih sofisticiranijih sustava za detekciju požara.

S obzirom na navedeno, može se postaviti sljedeći problem istraživanja:

*'Iako su do sada razvijene razne metode korištenja novih tehnika i tehnologija u brodskim vatrodojavnim sustavima, od kojih su kroz neke uvedena značajna poboljšanja za bolji rad sustava u praksi, još uvijek postoji veliki prostor za daljnja istraživanja u smjeru učinkovitijeg rada sustava brodske vatrodaje kao temelja povećanja sigurnosti posade, putnika i broda u cijelosti. Znanstvenim istraživanjima i primjenom novih elektroničkih i*

-----

*računalnih tehnologija omogućava se realizacija inteligentnih rješenja za upotrebu u brodskim vatrodojavnim sustavima u svrhu njihovog učinkovitijeg rada.'*

Sukladno problemu istraživanja definiran je i predmet istraživanja ove doktorske disertacije:

*'Sustavno istražiti i utvrditi sve relevantne praktične i teorijske značajke primjene novih elektroničkih i računalnih tehnologija i tehnika u brodskim vatrodojavnim sustavima te istražiti mogućnost primjene i implementacije novih rješenja u brodske vatrodojavni sustav.'*

Prethodno definirani problem i predmet znanstvenog istraživanja odnose se na nekoliko značajnih objekata istraživanja, kao što su: detektori i tehnologija detektiranja, upotreba inteligentnih algoritama upravljanja sustavom vatrodjave, modeliranje i optimizacija vatrodojavnog sustava, tehnologija obrade i analize slike, numerička analiza rizika požara i požarnih posljedica.

## **1.2. Znanstvena hipoteza i pomoćne hipoteze**

S obzirom na izneseni problem, predmet i objekte znanstvenog istraživanja postavljena je i temeljna znanstvena hipoteza:

*'Primjenom novih elektroničkih i računalnih tehnologija i tehnika u svrhu unaprjeđenja broorskoga vatrodojavnog sustava, povećava se efikasnost automatske detekcije požara, uz povećanje stupnja raspoloživosti i sigurnosti sustava brodske vatrodjave, te zaštite broda od požara.'*

Iz temeljne znanstvene hipoteze koja se direktno odnosi na predmet znanstvenog istraživanja proizlazi i nekoliko pomoćnih hipoteza:

PH 1: Primjenom novih elektroničkih i računalnih tehnologija u svrhu detektiranja incidentnih požarnih situacija, povećava se pouzdanost vatrodojavnog sustava.

PH 2: Unaprjeđuju se karakteristike broorskog vatrodojavnog sustava, posebno s aspekta povećanja brzine detekcije rane faze nastanka požara.

PH 3: Smanjuje se broj detektiranih lažnih alarma.

PH 4: Smanjuju se mogući troškovi izazvani požarnim incidentom.



### 1.3. Svrha i ciljevi istraživanja

Svrha ove doktorske disertacije je sustavno i znanstveno utemeljeno istražiti i analizirati mogućnost primjene novih elektroničkih i računalnih tehnologija u sklopu broorskoga vatrodojavnog sustava, kao što je upotreba računalnog vida u otkrivanju dima ili plamena, a s ciljem brže detekcije u određenom broorskom prostoru, te uz realne podatke prikupljene na brodovima, razviti i odgovarajući model i metodu, koji će se moći primjenjivati i u daljnjim znanstvenim istraživanjima. U skladu s predmetom i problemom te s obzirom na svrhu rada, nužno je ostvariti i sljedeće postavljene ciljeve:

- upoznavanje s problematikom kojom se susreću istraživači u navedenom području
- definiranje utjecajnih čimbenika na rad senzora broorskoga vatrodojavnog sustava
- upoznavanje s postojećim modelima, algoritmima i rješenjima primjenjivima na broorskim sustavima vatrodaje
- prijedlog mjera za povećanje efikasnosti broorskoga vatrodojavnog sustava
- unaprjeđenja postojećih metoda detekcije dima i plamena
- optimizacija alokacije senzora za detekciju dima, plamena i temperature
- definiranje dinamičke karakteristike dima i plamena na temelju provedenih eksperimenata u svrhu poboljšanja kvalitete detekcije
- definiranje utjecajnih čimbenika na rad kamera u svrhu detektiranja dima ili plamena
- razvoj novih metoda otkrivanja požarnih lokacija upotrebom video tehnologije i računalnog vida
- korištenje stvarnih rezultata dobivenih provedbom eksperimenata ostvarenih na brodu u stvarnom vremenu i realnim broorskim uvjetima za potrebe evaluacije uspješnosti predloženog modela broorskog vatrodojavnog sustava.

### 1.4. Pregled i ocjena dosadašnjih istraživanja

Za detaljno proučavanje područja istraživanja pretražene su sve najznačajnije baze podataka kao što su: Web of Science (WoS), IEEE Xplore Digital Library, Science Direct, Scopus, SpringerLink, Amazon, Google Scholar i sl. Iako je prikupljeno više stotina bibliografskih jedinica, za potrebe istraživanja odabrano je njih 115 koje su podijeljene u pet skupina: Knjige (6), Doktorske disertacije i magistarski radovi (8), Radovi objavljeni u

-----

znanstvenim časopisima i zbornicim (69), Predavanja, izlaganja, izvještaji, studije, ... (2), Priručnici (3), Ostali izvori (7) i Internetski izvori (20).

Zaštita od požara kao primjena znanosti i inženjerstva, načela su za zaštitu ljudi, imovine i okoliša od posljedica djelovanja požara. Razvoj pametnih senzora korištenjem novih tehnika i tehnologija u funkciji optimizacije vatrodojavnog sustava, predmet je stručnih i znanstvenih istraživanja u svrhu unaprjeđenja broetskog vatrodojavnog sustava.

Što se tiče sustava videotehnologije za otkrivanje požara, koje je i dalje aktualno područje istraživanja, iako postoji samo nekoliko sustava (VisiFire, SigniFire, FireVu, SFA sustav) koji su komercijalno dostupni uglavnom za otkrivanje šumskih požara.

Istraživanje čimbenika koji utječu na razvoj vatrodojavnih sustava značajnije se provodi posljednja dva desetljeća. So i Chan (1994) te Muller i Fischer (1995) koriste MSbFD algoritam neizrazite logike s dva požarna parametra (temperatura i optička gustoća dima) u svrhu procjene i interpretacije požarnog signala. Dva glavna cilja njihovog znanstvenog istraživanja su bila analiza ponašanja lažnih alarma te poboljšanje sposobnosti otkrivanja požara korištenjem više od jednog senzora. Frederick W. i suradnici (2001) bavili su se poboljšanjem postojećih sustava za dojavu požara s ciljem povećanja osjetljivosti detekcije, smanjenjem vremena otkrivanja i povećanjem pouzdanosti sustava za detekciju kroz smanjenja smetnji koje uzrokuju lažne alarme, upotrebom višekriterijske tehnologije otkrivanja požara u realnom vremenu. Osnovna svrha projekta autora J. A. Milke i suradnika (2003) pod naslovom *“Investigation of Multi-Sensor Algorithms for Fire Detection”* je pomoću prethodno provedenih testova i skupljenih podataka različitih vrsta senzora razviti algoritam koji uključuje kombinaciju signala iz svakog senzora, te uz identificirane karakteristike dima, plamena, tj. vatre, osigurati brz pokazatelj prisutnosti vatre.

Značajan doprinos u upotrebi videotehnologije za otkrivanje požara na brodu imali su Daniel T. Gottuk i suradnici (2005). Cilj njihovog rada bio je procijeniti djelotvornost videosustava detekcije požara za male, zatrpene prostore kao što su prostori na brodovima. Primarni cilj je bio analiza osjetljivosti i ograničenja videotehnologije za različita mjesta požarnih incidenata u uvjetima okoline koji se mogu pojaviti na brodu, a izloženi su raznim plamenim i tinjajućim izvorima vatre i potencijalnim izvorima smetnji. Uz pomoć algoritama detekcije dima, računalne obrade i tehnologije analize slike, dokazali su da korištenje videotehnologije ima brži i veći postotak uspješnosti u otkrivanju požara nego što je to slučaj kod upotrebe klasičnih detektora dima.

-----

U novije vrijeme Henry Joseph Gech i Yusuf Hakan Habiboglu (2005) provode eksperimentalna istraživanja vezana uz upotrebu karakteristike boje plamena. Sustav detekcije videokamerom obrađuje videosignal uspoređujući intenzitet i/ili boje pojedinih piksela ili skupinu piksela s videomatricom, kako bi se komparirale karakteristike i međudnos tih piksela te kako bi se otkrila prisutnost dima ili plamena.

Varun Pande i suradnici (2006) koriste algoritam otkrivanja požara mjerenjem temperature koristeći boju slike. Radom su dokazali da se odnos vrste požara i boje požara može koristiti i u otkrivanju veličine požara.

Alan J. Kouchinsky (2007) vrši ispitivanje koristeći Signi Fire videosustav za otkrivanje dima ili tinjajućeg plamena na velikim udaljenostima ili visinama. Cilj ispitivanja bio je analiza značajnih parametara koji utječu na aktivaciju alarma požara. Kao rezultat istraživanja razvijen je algoritam kao prvi korak prema uporabi videosustava za projektiranje zaštite od požara. Osim na analizi slike, algoritam se temelji i na osnovi analize dinamike širenja požara. Koristeći najnoviju tehnologiju za obradu slike, ispitivanjem nekoliko parametara kao što su kontrast, pokret, boja i pregled, algoritam nadzire njihov pojedinačni doprinos u realnom vremenu te otkriva pojavu dima ili vatre.

Cilj projekta autora Daniel T. Gottuka i Hughes Associatesa (2008) bio je stvaranje ograničenih standarda i propisa te kriterija u projektiranju videovatrodojavnih sustava koji se primjenjuju na kopnu.

Anrag Kadasne i suradnici (2009) u projektu LO3 bave se uporabom infracrvenih (IR) kamera za rano otkrivanje mogućeg požara pomoću sposobnosti otkrivanja infracrvenih valova, valnih duljina između 0,78 i 1,00  $\mu\text{m}$ , odnosno sposobnosti razlikovanja infracrvenih valova različitih valnih duljina.

Radom na istraživačkom projektu SURSHIP, Tuula Hakkarainen i suradnici (2009) kao dio koordiniranog europskog istraživačkog programa, proveli su istraživanja odnosa između materijala koji se koriste u brodogradnji, opasnosti od požara na brodu, strukturi broda i uvjetima evakuacije uslijed požara. Uporabom simulacije požara, tj. simulacijskog programa vatre FDS5 i simulacijskog programa evakuacije *Evac*, uz pomoć dostupnih baza podataka kao i kvantitativnih analiza rizika od požara pojedinih brodskih prostora, stvorili su projektne rezultate koji mogu utjecati na IMO pravila za konstrukciju brodova te zaštitu od požara.

-----

Jessica Ebert i Xiaojun Qi (2010) u svom istraživačkom radu obrađuju upotrebu računalnog vida za automatsko otkrivanje prisutnosti dima i vatre u videosekvenci. Algoritam za otkrivanje prisutnosti dima ili plamena, ne koristi samo attribute pokreta požara i boju, odnosno RGB vrijednosti požara i svojstva zasićenosti intenziteta HSV boja prostora, već i analizu vremenske varijacije boje vatre i sklonost vatre da se grupira oko središnje točke.

Novi način otkrivanja požara u realnom vremenu na temelju HMMS metode, odnosno na temelju skrivenog Markovljevog modela, rezultat je istraživanja Zhu Tenga i Jeany Hyun Kima (2010). Njihova metoda detekcije bazirala se na analizi karakteristika požara uporabom skrivenog Markovljevog modela, a zatim na analizi pomoću algoritma za otkrivanje piksela, odnosno pokreta dima ili plamena u prostoru. Eksperimentalni rezultati provedeni tijekom istraživanja pokazali su da predložena metoda pruža visoki stupanj detekcije i nisku stopu lažnih alarma.

U svom radu Sun Joe Ham i Byoung Chul Ko (2010), predlažu novi način detekcije požara pomoću metoda vjerojatnosti vizualnih značajki i FFA (engl. Fuzzy Finite Automat) metode. Istraživanjem su došli do zaključka da predloženi algoritam pokazuje bolje performanse detekcije požara u usporedbi s drugim metodama, te da ga se može uspješno implementirati u različite videotehnologije.

Metodu detekcije dima i plamena koristeći algoritam pokreta u realnom vremenu, registrirajući poziciju dima ili plamena u videosekvenci, a zatim spektralnom, prostornom i vremenskom analizom dima ili plamena, u svom istraživačkom radu su izložili Chao Ching Ho i Tzu Hsin Kou (2011). U njihovom radu gustoću vjerojatnosti predstavlja usporedba boje dima ili plamena s bojom histogram modela, gdje se koristi HSI boja prostora. Prostorna gustoća vjerojatnosti predstavlja izračun turbulentne pojave dima ili plamena s obzirom na opseg i područje nastanka. Njihovi eksperimentalni rezultati pokazali su da je predloženi model detekcije dima i plamena vrlo pouzdan.

Danijel Popesku i Calin Ciufudean (2011) u svom radu opisuju razvojne smjernice automatske detekcije požara uporabom VISD tehnologije (videodetekcija dima uporabom videoslike) i VIFD tehnologije (videodetekcija plamena uporabom videoslike). Dok su VISD tehnologiju temeljili na usporedbi zamrznute slike u realnom vremenu i detekciji prisutnosti dima u realnom vremenu s obzirom na pozadinu, VIFD tehnologijom su analizirali odnos snimljenih slika, u potrazi za specifičnim karakteristikama otvorenog plamena.

Lian Wang (2011) u svojem istraživačkom radu trodimenzionalne numeričke simulacije kretanja dima u brodskoj strojarnici, proučava širenje dima u višeslojnim i jednoslojnim strukturama brodske strojarnice korištenjem jednadžbi filtrirane ravnoteže i Smagorinskijevog modela. Kroz svoje primjere, Wang je ukazao na nedostatke tradicionalnog načina postavljanja detektora kod kojeg se ne uzimaju u obzir uvjeti okoline te predlaže poboljšanja za izučavanje požara na brodovima, što se u konačnici koristi i kod optimizacije kapaciteta broetskoga vatrodojavnog sustava.

Byoung Chul KO i suradnici (2011) u svojem istraživačkom radu bave se problemom detekcije požara na temelju plamena nepravilne karakteristike, nejasnog oblika i uzorka boje, te predlažu novu metodu detekcije pomoću neizrazitih konačnih automata i funkcije vjerojatnosti gustoće plamena na temelju vizualne mogućnosti, čime se osigurava sustavan pristup rukovanju nepravilnostima u računalnim sustavima i sposobnost kontinuirane obrade određenog prostora.

U svojem istraživačkom radu P. Morerio i L. Marcenano (2012) bavili su se otkrivanjem piksela dima i plamena pomoću algoritma detekcije pokreta. Izbor piksela su temeljili na dinamici područja detekcije, kako bi smanjili mogućnost detekcije lažnih požara.

Trendovi razvoja sustava vatrodaje i senzorskih tehnologija kreću se prema razvoju novih tipova detektora, odnosno integraciji više vrsta senzora u jedan detektor te implementaciji softverskih rješenja s ciljem brže, efikasnije i pouzdanije vatrodaje. Zahvaljujući novim tehnologijama inteligentnih senzora i namjenskim softverskim sučeljima, već u današnje vrijeme automatski detektori vatrodaje ostvaruju visoku razinu inteligencije. Parul Mohindru i Rajdeep Singh (2013) kroz svoj rad opisuju korištenje multisenzora preko bežičnih senzorskih mreža (WSN) koristeći neizrazitu logiku i podatke prikupljene s više senzora. Svaki čvor, tj. senzor, prikuplja podatke temperature, intenzitet svjetla i gustoću dima što u konačnici poboljšava preciznost sustava vatrodaje te smanjuje stopu lažnih alarma. Za sada se takvi sustavi najčešće koriste na kopnu, dok je upotreba bežičnih senzora na brodovima još uvijek u fazi ispitivanja.

Kroz svoj rad A. Enis Cetin i suradnici (2013) izrazili su uvjerenje da će kombiniranje analize podataka pomoću multimodalnog videopristupa, koristeći vidljivu i infracrvenu tehnologiju, dovesti do veće točnosti detekcije. Također, zalažu se za razvijanje sustava za otkrivanje požara pomoću postojećih CCTV televizijskih sustava, bez uvođenja bilo kakvih dodatnih troškova.

### 1.5. Znanstvene metode

U ovoj doktorskoj disertaciji, slijedom istraživanja primjene novih elektroničkih i računalnih tehnologija u vatrodojavnim sustavima, a u funkciji učinkovitijeg otkrivanja dima ili plamena na brodu, istraživanja su se vršila u više pravaca, uključujući teorijska i eksperimentalna istraživanja. Dio ispitivanja za potreba disertacije izvršeno je u brodogradilištu Uljanik na referentnom plovnom objektu, u realnom vremenu i u stvarnim brodskim eksploatacijskim uvjetima te se razvio model detekcije dima upotrebom klasičnog vatrodojavnog sustava i videotehnologije, koji će koristeći pojedine realne izmjerene parametre, služiti za unaprjeđenje broetskog vatrodojavnog sustava. Izvršena je usporedba dobivenih rezultata u brzini detekcije otkrivanja dima ili plamena pomoću klasičnih vatrodojavnih senzora i detekcije upotrebom videotehnologije, tj. računalnog vida.

Prilikom znanstvenog istraživanja, prezentacije i analize rezultata istraživanja koristilo se više kombiniranih istraživačkih metoda. Metode mjerenja i projektiranja dinamičkih procesa dima i vatre u realnom vremenu korišteni su za simulaciju i obradu raspoloživih podataka vatrodojavnog sustava. Pri razvoju predloženog modela detekcije dima, koristila se metoda s dostupnim programskim rješenjima. Za donošenje općih zaključaka o značajkama vatrodojavnog sustava koristila se induktivna i deduktivna metoda. Metode deskripcije i dedukcije su se koristile prilikom opisa problema i u donošenju temeljnih postavki za vrednovanje primjene novih elektroničkih i računalnih tehnologija te tehnika u sklopu broetskog vatrodojavnog sustava. U okviru sistematizacije i usporedne analize primijenile su se metode formalne i komparativne analize. Za prihvaćanje ili opovrgavanje postavljenih teza koristile su se metode dokazivanja i opovrgavanja. Također su se koristile i metoda kompilacije za pregled dosadašnjih istraživanja i radova, te metoda intervjuiranja za prikupljanje potrebnih informacija od proizvođača brodske vatrodojavne opreme i ostalih eksperata iz ovoga područja.

### 1.6. Struktura doktorske disertacije

S obzirom na predmet i problem istraživanja te objekte istraživanja, ova doktorska disertacija podijeljena je u sedam poglavlja koja čine jednu funkcionalnu cjelinu.

U prvom dijelu, UVODU, definirani su problem istraživanja, postavile su se znanstvene hipoteze (glavna i pomoćne), opisale svrha i ciljevi istraživanja, dan je pregled, navedene su korištene znanstvene metode i obrazložena je struktura rada.

U drugom dijelu pod naslovom KARAKTERISTIKE KLASIČNIH BRODSKIH VATRODOJAVNIH ALARMNIH SUSTAVA, predstavljene su osnovne karakteristike i vrste vatrodojavnih sustava, komponente sustava vatrodjave, struktura broorskog vatrodojavnog sustava, osnovne funkcije, specifičnosti detektora, zahtjevi registara koji se odnose na pravila i propise s obzirom na tip broda te međunarodni uvjeti koje moraju ispunjavati broski vatrodojavni sustavi. Osim toga, analizirana je pouzdanost i raspoloživost broorskog vatrodojavnog sustava.

Treći dio pod naslovom UZROCI NASTANKA I KARAKTERISTIKE POŽARA NA BRODOVIMA obuhvatio je definiranje utjecajnih čimbenika za razvitak broorskog požara s obzirom na nastanak i njegov razvoj. Također, opisane su faze nastanka požara, faze razvoja i faze prijenosa požara na brodu te dinamičke karakteristike dima i vatre u fazi nastajanja požarnog incidenta sustavno opisujući mogući scenarij određenog dijela broorskog prostora zahvaćenog požarom.

U četvrtom dijelu pod naslovom NOVE ELEKTRONIČKE I RAČUNALNE TEHNOLOGIJE U BRODSKIM VATRODOJAVNIM SUSTAVIMA obrazložena je primjena višekriterijske tehnologije u otkrivanju požara. Sustavno su se obradila nova tehnička rješenja u otkrivanju dima ili plamena uvođenjem novih sofisticiranih multi-detektora, videodetekcije i robotike, te korištenje nanotehnologije u detektorima i komponentama broorskog vatrodojavnog sustava. Također, obradili su se svjetlovodni detektori temperature, videotehnologija u otkrivanju dima, temperature i plamena, te opisala primjena računalne inteligencije i tehnologije računalnog vida.

PRIJEDLOG MODELA BROORSKOGA VATRODOJAVNOG SUSTAVA TEMELJENOG NA RAČUNALNOM VIDU naslov je petog poglavlja u kojem je dan opis primjene računalnog vida u detekciji rane faze nastanka požara na brodu kroz opis samog videonadzora, obradu i analizu videozapisa u realnom vremenu, te detekciju dima korištenjem tehnologije računalnog vida. Nadalje, izrađen je model za analizu videozapisa temeljen na računalnom vidu obradom slika u svrhu detekcije dima. Isto tako, razmotrila su se ograničenja modela i izvršila se analiza čimbenika koji su utjecala na pouzdanu detekciju dima. Obrazložio se prijedlog strukture broorskog vatrodojavnog sustava temeljenog na novim elektroničkim i računalnim tehnologijama, opisujući strukturu i dijelove predloženog vatrodojavnog sustava i komunikacijskih protokola uz analizu mogućih scenarija širenja požara.

Šesti dio pod naslovom EVALUACIJA USPJEŠNOSTI PREDLOŽENOG MODELA BRODSKOGA VATRODOJAVNOG SUSTAVA TEMELJENOG NA RAČUNALNOM VIDU uz uvodna razmatranja, odabir i definiranje početnih uvjeta reprezentativnih scenarija za analizu detekcije rane faze nastanka požara, donosi ispitivanje predloženog modela u stvarnim uvjetima na brodu. Prikupljanjem podataka, definiranjem kriterija za ocjenu uspješnosti predloženog modela, odnosno analizom uspješnosti predloženog algoritma s obzirom na postignutu brzinu odziva i točnost detekcije, izvršila se analiza dobivenih rezultata. Komparativnom analizom klasičnog i predloženog pristupa u detekciji rane faze nastanka požara, uz iste početne uvjete (kapacitet, volumen, strujanje zraka, visina, osvjetljenje i dr.) izvršilo se ispitivanje na standardni način baziran na standardnim detektorima, te pomoću predloženog sustava temeljenog na računalnom vidu. U tu svrhu rezultati ispitivanja provedenih u brodogradilištu *Uljanik*, na brodu postignuti su u realnim brodskim uvjetima. Također, provedena je analiza s obzirom na brzinu odziva, točnost i pouzdanost pojedinog pristupa detektiranja. Na kraju analizirana je i ekonomska opravdanost predloženog modela u funkciji povećanja sigurnosti na brodu i smanjenja ukupnih troškova koji mogu biti uzrokovani nepravovremenom detekcijom rane faze nastanka požara. Izvršila se i komparativna analiza predloženog modela u odnosu na klasični pristup s aspekta početnih troškova i troškova održavanja. Istaknuti su povećanje sigurnosti na brodu, zaštita ljudi i imovine, smanjenje troškova osiguranja, te povoljniji utjecaj na okoliš.

U posljednjem, sedmom dijelu ZAKLJUČAK izneseni su rezultati predstavljenih istraživanja na temelju kojih se mogu prihvatiti postavljene hipoteze. Također su dane preporuke i pravci za daljnja istraživanja.



## **2. KARAKTERISTIKE BRODSKIH VATRODOJAVNIH ALARMNIH SUSAVA**

Vatrodojava je prva faza cjelokupnog procesa gašenja požara, te kao takva ovisi o brzini otkrivanja vatre kao vrlo važne komponente slijeda sprječavanja neželjenih posljedica. Današnji sustavi detekcije požara, dizajnirani po svim svjetskim standardima, odlikuju se velikom pouzdanošću, preciznošću, učinkovitosti i brzinom otkrivanja vatre, odnosno plamena i dima.

U svakom sustavu vatrodaje važne funkcije su otkrivanja požarnog incidenta, prijenosa signala, skladištenje informacija, računanje i prikaz alarmnih događaja i ostalih informacija kojom raspolaže sustav vatrodaje.

U početku su vatrodajni sustavi imali problem u procesu prikupljanja podataka zbog vremenskog kašnjenja požarnog signala i vrlo velikom stopom lažnih alarma. Tijekom vremena razvili su se inteligentni vatrodajni sustavi temeljeni na mikroprocesima. Uvođenjem mikroprocesora poboljšane su učinkovitosti raznih aplikacija kao pametnih odnosno inteligentnih funkcija otkrivanja požara u realnom vremenu. Neke od odlika tih funkcije su [1]:

- točna identifikacija mjesta nastanka požara
- brzina detekcije
- smanjenje lažnih alarma
- automatsko testiranje vatrodajnih krugova (petlje)
- jednostavnost održavanja sustava
- zapis povijesti događanja
- smanjenje troškova ožičenja instalacija.

Osim gore navedenih funkcija inteligentni vatrodajni sustav osigurava i brz pristup informacijama samog sustava kao što su: ispravnost komponenti sustava programskom podrškom, kontrolom AC i DC napajanja, izlaznim signalima i njihovom logikom.

Daljnijim razvojem tehnologije omogućen je razvoj softverskog sustava vatrodaje kojim se može podešavati osjetljivost detektora uz mogućnost automatske kompenzacije praga detekcije uslijed zaprljanosti detektora prašinom. Također, softver pruža mogućnost dodavanja ili brisanja pojedinih detektora, mijenjanja ulazno-izlaznih signala, blokiranja

-----

detektora, zona ili cijele požarne petlje, mijenjanje naziva pozicija smještaja detektora. Mali nedostatak novih inteligentnih sustava je u tome što se mora proći određena obuka osoblja radi što lakšeg upravljanja i servisiranja sustava.

## **2.1. Detektori alarmnog broetskog vatrodojavnog sustava**

U početku, detektor otkrivanja požara bio je sam čovjek koristeći osjetila vida, mirisa i osjet temperature. Razvojem industrijske tehnologije, sposobnost ljudskih osjetila za otkrivanja vatre zamijenili su detektori. Toplinski detektori su slični našoj sposobnosti identificiranja temperature, detektori plamena su elektroničke oči, a dimni detektor replicira osjećaj za miris. Svrha razvoja detektora je neophodnost ranog otkrivanja požara, ograničenje i kontrola te gašenje vatre prije nego ona izmakne kontroli ugrožavajući život, brod, teret i okoliš. Dobro osmišljen, pravilno instaliran, dobro održavan vatrodojavni sustav s odgovarajućim tipovima detektora za određena mjesta detekcije, doprinijet će ranim otkrivanjem i pravovremenim upozorenjem o točnom području požara.

### **2.1.1. Klasifikacija detektora**

Svojstva na osnovi kojih se vrši klasifikacija automatskih detektora požara, su ona svojstva koja mogu otkriti prisutnost požara, odnosno parametri koji pokazuju prisutnost topline, dima, plamena, plinova, zračenja. Također, u literaturama postoji više načina podjela detektora požara kao što je podjela na bazi osjetljivosti detektora ili na osnovi granice detekcije, gdje se detektori klasificiraju na točkaste (detekcija požara u točki određene okoline) i linijske (detekcija promjene okoline određene linije).

Većinu suvremenih vatrodojavnih detektora čine točkasti detektori koji reagiraju na promjenu količine dima, promjenu temperature ili temperaturne razlike i zračenja uzrokovano plamenom ili vatrom u blizini detektora. Kao tipičan linijski vatrodojavni detektor temperature je termički kabel. Njegov rad bazira se na reakciji promjene temperature u neposrednoj blizini kabla. Detektori sa svjetlosnim snopom smatraju se također linijskim detektorima dima koji rade na principu odašiljanja infracrvene svjetlosti od predajnika ka prijemniku mjereći pritom promjenu količine čestice dima na putu infracrvene svjetlosti.

Toplinski detektori imaju zadatak otkriti temperaturu više vrijednosti od temperature ambijenta, temeljene na promjeni porasta temperature uslijed promjena fizičkih ili kemijskih

-----

svojstava kao što su varijacije električnih polja, loše izolacije i drugo. Inače temperaturni detektori izrađeni su od metala, nemetala, bimetala, a također kao medij koriste tekućine ili plinove.

Parametri detektora dima baziraju se na razini otkrivanja čestica dima bilo na temelju optičkih svojstava zamračenja, varijacije indeksa loma svjetlosti, fotoelektričnih svojstava, ili promjenama u vodljivosti ioniziranog zraka.

Detektor zračenja kao parametre koristi razinu zračenja na temelju podrhtavanja plamena, iskre, odnosno ultraljubičastog ili infracrvenog zračenja promjenom temperature predmeta, okoline, određenog medija. Detektor plina otkriva razinu koncentracije plina pomoću infracrvene apsorpcije metodom mjerenja varijacije brzine zvuka u različitim koncentracijama plina.

#### **2.1.1.1. Temperaturni detektori**

Temperaturni detektori su jedan od najstarijih oblika automatskih uređaja za otkrivanje požara. Obično imaju najnižu stopu lažnih alarma od svih automatskih uređaja za otkrivanje požara. Ipak, oni su općenito najsporiji detektori u otkrivanju vatre jer ne posjeduju funkciju otkrivanja dima. Dakle, detektori temperature često ne pružaju dovoljno rano upozorenje u slučaju po život opasne situacije. Kao rezultat toga, detektori temperature su najprikladniji za otkrivanje požara u malim uskim prostorima u kojima se očekuju brze i velike temperature požara, u područjima gdje uvjeti okoline ne dopuštaju korištenje detektora za otkrivanje požara, odnosno gdje je brzina otkrivanja nije primarna.

Detektori topline uglavnom se nalaze na ili u blizini stropa, gdje su toplinske energije vatre najizraženije. Također, temperaturni detektori se mogu koristiti u kombinaciji s detektorima dima, jer detektori dima obično aktiviraju prisutnost dima prije nego li se aktivira plamen, odnosno temperatura izazvana požarnim incidentom.

Princip rada temperaturnih detektora zasniva se na reakciji povećanja temperature nastale u prostoriji kao posljedica požara. Općenito, detektori temperature su dizajnirani da rade kada toplina uzrokuje promjenu svojstva materijala ili plina, bilo fizičko ili električno. Postoje dvije vrste temperaturnih detektora:

- Termodiferencijalni detektori koji mjere promjenu temperature i reagiraju na nagli porast temperature, primjenjuju se u područjima gdje je povišena temperatura normalna pojava, kao kuhinje, radionice i slično.

- 
- Termomaksimalni detektori koji mjere fiksnu temperaturu i reagiraju kada temperatura dostigne definiranu vrijednost, primjenjuju se u područjima gdje su velike promjene temperatura (npr. parni kotao) ili gdje je temperatura neuobičajena visoka.

Prijenos topline na temperaturne detektore može se opisati jednadžbom;

$$Q_{ukupno} = Q_{kond} + Q_{konv} + Q_{rad} , \quad (2.1)$$

gdje su:

$Q_{ukupno}$  = ukupni prijenos topline na detektor (kW)

$Q_{kond}$  = vodljivi prijenos topline (kW)

$Q_{konv}$  = konvektivni prijenos topline (kW)

$Q_{rad}$  = prijenos topline zračenjem (kW).

Kako znamo da se početak otkrivanja požara obično javlja tijekom početne faze požara, komponenta zračenja – prijenos topline ( $Q_{rad}$ ) tada se smatra zanemarivom. Isto tako, pošto se toplina očitavanja raznih elemenata ne može korektno očitavati jer su toplinski izolirani, kao što su brodske strojarnice, tada se smatra da je vodljivi dio topline ( $Q_{kond}$ ) zanemariv, pogotovo u usporedbi s brzinom prijenosa topline konvekcijom. Većina prijenosa topline na elemente je putem konvekcije, tako da sljedeća jednadžbe za izračunavanje ukupnog prijenosa topline glasi:

$$Q = Q_{konv} = H_c A (T_g - T_d) , \quad (2.2)$$

gdje su:

$Q_{konv}$  = konvektivni prijenos topline (Kw)

$H_c$  = koeficijent prijenosa konvektivne topline (kW/°C)

$A$  = površina detekcije (m<sup>2</sup>)

$T_g$  = temperatura požarnih plinova (°C)


$T_d$  = temperatura alarma (alarmna točka u °C).

Na brodu se uglavnom koriste temperaturni detektori koji u sebi imaju ugrađen termomaksimalni ili termodiferencijalni detektor. Prema SOLAS konvenciji za temperaturne detektore važi da aktivacija termičkog senzora mora biti prije zadane temperaturne granice od 78 °C, uz uvjet da temperatura raste i prijeđe 54 °C, maksimalnom brzinom do 1°C u minuti. Ukoliko je temperatura rasta brže, tada aktivacija detektora mora biti na temperaturi određenoj projektom [4]. Obično detektori koji rade u rasponu 54 -78 °C treba instalirati samo ako stropna temperatura ne prelazi 37,7 °C.

#### 2.1.1.1.1. Fiksni temperaturni detektori (termomaksimalni temperaturni detektori)

Prva generacija vatrodjave (1849. – 1940.) bazirana je na fiksnim toplinskim detektorima. Preteča prvim temperaturnim senzorima je uvođenje bimetala krajem 19. stoljeća. Njihov rad zasnivao se na principu nejednake ekspanzije između dvaju metala. Budući da različiti metali imaju različita svojstva povezani jedan s drugim, savijati će se u jednom smjeru kad se zagriju, a u suprotnom smjeru kada se ohlade, (pojam bimetalni termometar ili skraćeno BiMets) [5].

BiMets kao pouzdan i izdržljiv, tada se smatrao idealnim za mnoge industrijske primjene, pa tako i za upotrebu u vatrodjavi, kao prvi vatrodjavni detektor korišten za zaštitu od požara. Danas se također koriste detektori požara na principu bimetala.



Slika 1: Princip rada bimetalnog detektora

Izvor: Izradio autor prema [www.google.hr/search?q=bimetal&biw](http://www.google.hr/search?q=bimetal&biw)

Fiksni temperaturni detektori općenito koriste bimetalne komponente, čije su najčešće postavke temperature 130 °C. Kad temperatura unutar detektora dosegne podešeni parametar, tada će ići u alarmno stanje. Bimetalni detektor požara, nakon detekcije požarnog incidenta

najčešće će se vratiti u prvobitno stanje, no nekad se mora i mijenjati, jer bimetalna komponenta gubi sposobnost preciznosti, te se ne može ponovno koristiti.

Da bi fiksni temperaturni detektori imali dovoljnu stabilnost u radu, pretpostavljajući da temperatura ambijenta varira nužno je da detektor ne dostigne postavljeno alarmno stanje, odnosno prag detekcije. Prag alarma mora biti iznad maksimalne temperature okoline detektirane zone. Postavljanje temperaturne alarmne granice, odnosno praga detekcije prikazano je izrazom

$$Td = Tp - Tamax, \quad (2.3)$$


gdje su:

$Td$  = prag detekcije detektora

$Tp$  = temperatura detektora

$Tamax$  = maksimalna temperatura ambijenta u blizini detektora.

Aktivacija praga detekcije ovisi i o konstrukciji detektora stabilnosti i njegovog senzorskog elementa, koji je najčešće termistor. Često se susrećemo sa situacijom gdje je temperatura zraka za vrijeme rada detektora veća od temperature koju očitava senzor termalne inercije, odnosno sporijeg reagiranja. To stanje naziva se temperaturno kašnjenje.



Slika 2: Prikaz današnjih fiksnih toplinskih detektora na bazi bimetala

Vrijeme potrebno za aktivaciju fiksnog detektora jednadžbom u svom radu obrazložili su Budnick, Evans, i Nelson, 1997.

$$t_{aktivacije} = \frac{RTI}{\sqrt{u_{sb}}} \ln \left[ \frac{T_{st} - T_a}{T_{st} - T_{aktivacije}} \right] \quad (2.4)$$

gdje su:


$t$  = vrijeme aktivacije detektora (s)

$RTI$  = vrijeme odziva detektora  $(m \cdot s)^{1/2}$

$u_{sb}$  = stropna brzina mlaza plamena (m/s)

$T_{st}$  = stropna temperatura ( $^{\circ}\text{C}$ )

$T_a$  = temperatura zraka okoline ( $^{\circ}\text{C}$ ).



Slika 3: Prikaz stropnog mlaza plamena

Po standardu koji je usvojila 2007. g., organizacija "NFPA" (National Fire Protection Association), na osnovi testova provedenih od "FM Global Group", svi tipovi točkasto fiksnih temperaturnih detektora, detektora temperature koji prate temperaturne promjene i detektora temperature s autokompencijom, moraju imati vrijeme odziva ( $RTI$ ) u granicama navedenim u sljedećim tablicama [7].

Tablica 1: Vrijeme odziva ( $RTI$ ) za fiksne temperaturne detektore

Procjena temperature davača	Standardna	Hitra	Brza
57 $^{\circ}\text{C}$	< 68 $(m \cdot s)^{1/2}$	< 25 $(m \cdot s)^{1/2}$	< 3 $(m \cdot s)^{1/2}$
71 $^{\circ}\text{C}$	< 66 $(m \cdot s)^{1/2}$	< 22 $(m \cdot s)^{1/2}$	< 2 $(m \cdot s)^{1/2}$
88 $^{\circ}\text{C}$	< 66 $(m \cdot s)^{1/2}$	< 22 $(m \cdot s)^{1/2}$	< 2 $(m \cdot s)^{1/2}$

Izvor: Izradio autor prema NFPA, 2015.

Za sljedeću tablicu koja prikazuje vrijeme (*RTI*) za detektore koji reagiraju na porast (gradijent) temperature u jedinici vremena odnosno termodiferencijalne detektore, bez obzira na temperaturu okoline, treba napomenuti da se uzela u obzir brzina promjene temperature od 9 °C po minuti.

Tablica 2: Vrijeme odziva (*RTI*) za termodiferencijalne temperaturne detektore (9 °C/min)

Procjena temperature davača	Hitra	Brza	Vrlo brza	Ultra brza
57 °C	< 330 (m·s) <sup>½</sup>	< 135 (m·s) <sup>½</sup>	< 85 (m·s) <sup>½</sup>	< 66 (m·s) <sup>½</sup>
71 °C	< 520 (m·s) <sup>½</sup>	< 220 (m·s) <sup>½</sup>	< 145 (m·s) <sup>½</sup>	< 120 (m·s) <sup>½</sup>
88 °C	< 770 (m·s) <sup>½</sup>	< 320 (m·s) <sup>½</sup>	< 213 (m·s) <sup>½</sup>	< 193 (m·s) <sup>½</sup>

Izvor: Izradio autor prema NFPA, 2015.

Tablica 3: Vrijeme odziva (*RTI*) za detektore s autokompenzacijom


Procjena temperature davača	Hitra	Brza	Vrlo brza
57 °C	< 64 (m·s) <sup>½</sup>	< 29 (m·s) <sup>½</sup>	< 9 (m·s) <sup>½</sup>
71 °C	< 76 (m·s) <sup>½</sup>	< 39 (m·s) <sup>½</sup>	< 14 (m·s) <sup>½</sup>
88 °C	< 69 (m·s) <sup>½</sup>	< 30 (m·s) <sup>½</sup>	< 9 (m·s) <sup>½</sup>

Izvor: Izradio autor prema NFPA, 2015.

Jedna vrsta fiksnog temperaturnog detektora radi na bazi topljivog elemenata. Metal koji se koristi za pokretanje operativnog elementa temperaturnog detektora, kao što je opruga koja zatvara kontakt i pokreće alarm, je mješavina bizmuta, olova, kositra ili kadmija.

Isto tako postoje i linijski detektori koji koriste par žica u pravilu kao otvoreni krug u pletenici kabela. Kada se dostigne unaprijed određena temperatura, izolacija koja obuhvaća žicu, tj. vodiče, topi se i uslijed kratkog spoja žica, inicira se alarm. Kako bi sustav mogao normalno nastaviti rad dio kabela mora se zamijeniti novim, radi vraćanje sustava u normalu.






Slika 4: Linijski temperaturni detektori

Izvor: [www.utcssecurityproducts.eu](http://www.utcssecurityproducts.eu)

#### 2.1.1.1.2. Termodiferencijalni temperaturni detektori


Detektori vatrodojave koji reagiraju na rast temperature u vremenskoj jedinici ( $dT/dt$ ), ne uzimajući temperaturu okoline zone detekcije prije požarnog incidenta, i čija je reakcija vrlo brza, nazivaju se termodiferencijalni detektori. Ovi detektori osjetljiviji su na požar nego li termo-maksimalni detektori, kod kojih brzina reakcije zavisi od početne temperature okoline. Fiksni temperaturni detektori neće aktivirati alarm dok temperatura zraka u neposrednoj blizini stropa ne prelazi zadanu alarmnu točku. Međutim, kada temperatura premaši unaprijed zadanu vrijednost, obično oko  $7 - 8\text{ }^{\circ}\text{C}$  u minuti, detektor javlja alarm. Diferencijalni detektori su dizajnirani da kompenziraju normalnu promjenu temperature okoline ako je promjena manja od  $6$  do  $7\text{ }^{\circ}\text{C}$  u minuti.



Slika 5: Termodiferencijalni temperaturni detektor

### 2.1.1.1.3. Pneumatski temperaturni detektori

U pneumatskom temperaturnom detektoru povećavanjem temperature okoline odnosno zraka, zagrijava se ili cijev ili komora ovisno o vrsti detektora, čime se povećava tlak u cijevi ili komori. Tlak vrši mehaničku silu na dijafragmu pomoću koje se zatvara određeni kontakt za pokretanje alarma. Pneumatski detektori inače imaju mali otvor za ozračivanje koji bilježi brže promjene temperature, kao u slučaju požara, brzina širenja prelazi stopu za ozračivanje uslijed čega raste tlak. Kad je porast temperature veći od 7 do 8 °C u minuti, tlak vrši mehaničko djelovanje na fleksibilnu dijafragmu.



Slika 6: Elektropneumatski temperaturni detektor

### 2.1.1.2. Detektori dima

Detekcija dima doživjela je eksplozivni rast upotrebom detektora dima 1970. kao posljedica napretka tehnologije i proizvodnje, koja je uvelike smanjila cijene detektora i sustava detekcije požara općenito. Značajni napor u raznim istraživanjima imali su za cilj razumjeti okruženja u kojem se detektori nalaze, brzinu i točnost odgovora tih detektora. Justin Aaron Geiman se 2003. godine u svom istraživačkom radu bavio metodom aproksimacije procjene praga odgovora detektora dima na temelju optičkih gustoća, porasta temperatura i brzine protoka plina. Definicija predviđene optičke gustoće kao gustoću dima proizvedenu po jedinici mase potrošnje goriva prikazana je izrazom:

$$D_m = D_p \cdot y_s \quad (2.5)$$

gdje su:

$y_s$  = frakcija lebdećih čestica (dim) u odnosu na masu gubitka goriva

$D_p$  = približna konstanta optičke gustoće za razne gorive materijale

Predviđanje optičke gustoće dima temelji se na jednadžbi:

$$D_u = \frac{D_m \Delta m_f}{V_c} \cdot \frac{D_m m_f}{V}, \quad (2.6)$$

gdje su:

$D_u$  = optička gustoća po metru ( $m^{-1}$ )

$D_m$  = masa optičke gustoće goriva ( $m^2/g$ )

$\Delta m_f$  = gubitak mase goriva (g)

$V_c$  = volumen raspršene mase ( $m^3$ )

$m_f$  = stopa gubitka mase goriva (g/s)

$V$  = volumetrični protok ( $m^3/s$ ).

Znanstveni pristup predviđanja aktivacije detektora dima bilo ionizirajućeg ili fotoelektričnog u svom istraživačkom radu prezentirao je Mulholland (2002), pomoću empirijskog signala iz detektora dima kao integrirani produkt raspodjele veličine i funkcije odgovora detektora  $R(d)$  u skladu s jednadžbom:

$$S = \int_{d_{min}}^{d_{max}} R(d) \frac{\delta N}{\delta d} \delta d, \quad (2.7)$$

gdje su:

$S$  = električni signal detektora dima ( $\mu V$ )

$R(d)$  = funkcija odgovora detektora ( $\mu V cm^3$ )

$\frac{\delta N}{\delta d}$  = broj raspodjele veličina funkcija ( $cm^{-3} \mu m^{-1}$ )

$d$  = promjer čestica ( $\mu m$ )

-----


Primjena ovih znanstvenih saznanja gdje funkcija odgovora detektora dima  $R(d)$  ovisi o dizajnu i tipu namjene za koju je proizvođač namijenio detektor u realnim uvjetima ne mogu se koristiti, već samo prilikom raznih testova u znanstvenim istraživanjima.

#### **2.1.1.2.1. Ionizirajući detektor dima**

Povijesno gledano evolucija detektora dima može se podijeliti u četiri generacije temeljenih na razvoju kvalitete detektora uz tehnologijski razvoj elektroničke industrije. Prva generacija detektora dima, smatra se generacija prije 1960. Godine 1922. Greinacher iz Berna vodio je eksperiment za mjerenje udjela prašine u zraku, koja je smanjivala pokretljivost toka iona. Uslijed te činjenice 1922. u Biltenu švicarskog udruženja elektrotehnike, objavljuje rad o mogućoj upotrebi ionizirajuće komore za detekciju plina [9]. Prvi elektronski detektor za otkrivanje dima zapravo je plod pogreške. 1930. godine švicarski fizičar Walter Jaeger pokušao je razviti detektor za otkrivanje otrovnog plina. Mislio je da će se plin vezati za ionizirajući zrak, te tako promijeniti električnu struju u detektoru. Međutim, nakon što nije uspio nijedan test, Jaeger je zapalio cigaretu i dim je aktivirao detektor smanjenjem električne struje, što je dovelo do izuma prvog elektronskog uređaja za otkrivanje dima. Prvi patentirani dimni detektor izumili su ranih 40-ih godina švicarski znanstvenici Ermst Meila i Jaegara. Veliku prekretnicu u povijesti vatrodojavnih sustava je pojava ionizirajućeg detektora dima u ranim četrdesetim godinama prošlog stoljeća.

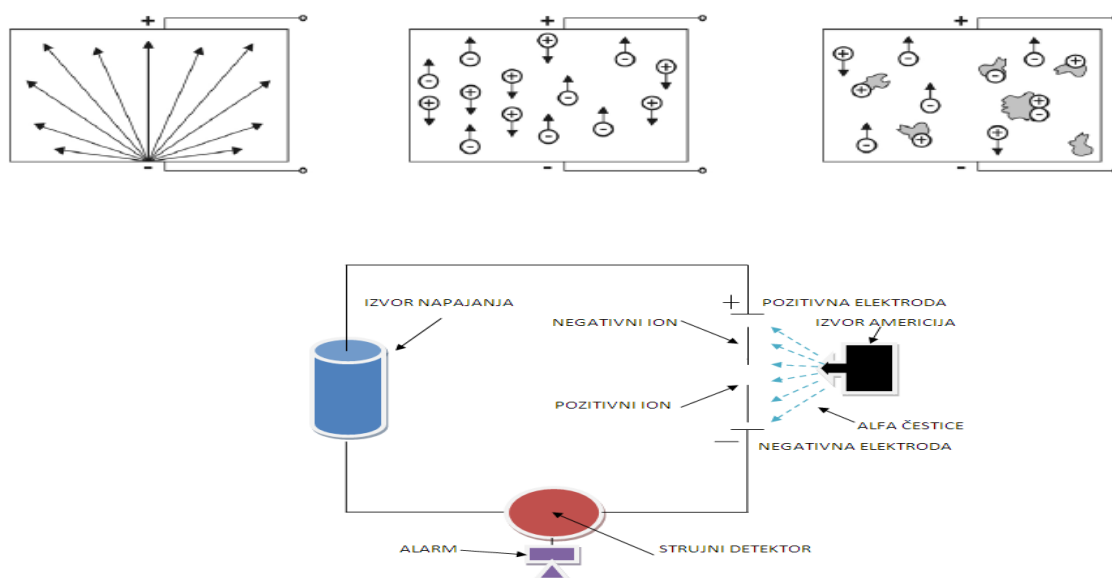
Ionizirajući detektori su i danas osnova najvećeg broja suvremenih alarmnih vatrodojavnih sustava. 1942. g. počinje komercijalizacija ionizirajućeg detektora dima – Cerberus. Godine 1960. kanadski znanstvenici proveli su ispitivanje požara u 342 stambena objekta, te su došli do zaključka da bi detektori dima smanjili broj smrtnih slučajeva za 41%, dok toplinski detektori samo 8 % [10].

U ranim 1960-im do 1975, razvila se druga generacija detektora dima, gdje je korišten americij 241 kao radioaktivni izvor za ionizaciju uz razvitak elektroničke industrije. 1964. godine Alert je razvio ionizirajući detektor dima koji se napaja s 24 V [11]. Ionizirajući detektori dima sadrže male količine radioaktivnog izotopa koji emitira alfa-čestice, koje sudjelujući u raspadanju americija 241, ioniziraju zrak stvarajući određeni strujni naboj. Prilikom koncentracije određene količine dima u samom detektoru ioni se uhvate za čestice dima što uzrokuje smanjenje struje naboja detektora. Odgovarajuće smanjenje struje naboja uključuje alarm.



Slika 7: Ionizirajući detektor dima

Rizik zračenja od ovakvih detektora je vrlo mali. Vrijeme poluraspada americitia 241 je oko 432 godine, odnosno raspada se vrlo sporo. Ionizirajući detektor dima i nakon što mu istekne radni vijek zadržava karakteristiku početne aktivnosti. Po međunarodnim pravilima svaki ionizirajući detektor mora imati odgovarajuću oznaku radioaktivnosti. Nakon upotrebe ovi senzori pohranjuju se na za to određeno mjesto kao radioaktivni otpad.




Slika 8: Električni krug ionizirajućeg detektora dima

Dim je jedan od prvih znakova vatre u većini slučajeva i stoga je otkrivanje dima važno za otkrivanje požara. Prednost ionizirajućih detektora dima upravo je osjetljivost na otkrivanje vrlo male količine dima, što je s gledišta sigurnosti jako dobro za brod.

### 2.1.1.2.2. Optički detektor dima


Godinu dana nakon otkrića ionizirajućeg detektora dima, Duane Pearsall razvio je fotoelektrični detektor dima, tj. optički detektor dima [12]. Velike promjene u tehnologiji dimnih detektora nastupile su sedamdesetih i osamdesetih godina prošlog stoljeća.

Detektori dima su izvorno razvijeni za sprječavanje izbijanja požara u industrijskim zgradama kao što su tvornice i skladišta te javne zgrade, gdje je veliki broj ljudi izložen mogućem požaru. Uobičajeno je da su ti sustavi, sustavno koriste i na svim tipovima brodova.




Slika 9: Optički detektor dima

Optički detektori dima prikazan na slici radi na principu prekida svjetlosnog snopa odnosno na tzv. Tyndallovom efektu. Detektor dima sastoji se od izvora svjetlosti, obično bijelo svjetlo ili češće lasera male snage te fotoelektrične stanice. Snop svjetlosti poslan preko detektora u normalnim uvjetima čistoće, zaobilazi fotočeliju obično postavljenu na 90 stupnjeva. Kad čestice dima priječe snop svjetlosti, dolazi do prijeloma zrake, koja usmjerena na fotoelektričnu čeliju mijenja fizikalne veličine te s obzirom na postavljene limite uzrokuje alarm.



Slika 10: Princip rada optičkog detektora dima s raspršenom svjetlošću

Postoji i jednostavna izvedba optičkih detektora dima s direktnom svjetlošću. Sastoji se od predajnika odnosno svjetlosnog izvora najčešće poluprovodna dioda i prijamnika, koji može biti fotodioda, zatim fotootpornik ili fototranzistor.



Slika 11: Princip rada optičkog detektora dima s direktnom svjetlošću

U redovnom stanju, bez dima, svjetlosni signal emitiran s predajnika dopire na prijamnik. Ukoliko je jačina signala na prijamniku identična jačini signala predajnika tada je to normalno stanje i nema alarma. Međutim, ulaskom dima u dio detektora, odnosno u optičku komoru dolazi do apsorpcije dijela svjetlosti i slabljenje signala na strani prijamnika odnosno i manji emitirani električni signal na prijamniku u odnosu na početni s predajnika. Ukoliko se signal smanji i padne ispod zadane granice alarmiranja, vatrodojavni optički dimni detektor prelazi u stanje alarma.

Treća generacija dimnih detektora (1975–1990) značajna je po povećanom interesu za dimnim detektorima požara. U tom razdoblju desilo se nekoliko bitnih promjena u detektorima, uključujući zamjenu žarne niti kao izvora svjetlosti sa svjetlom diode i korištenje silicija.

Četvrta generacija detektora dima (od 90-ih do danas) karakteristična je po upotrebi više detektora u jednoj petlji, uz korištenje algoritama. Razvoj mikroelektronike omogućio je integraciju sve većeg broja inteligentnih funkcija u samom detektoru te se na taj način neke funkcionalne procjene i odluke mogu izvoditi u samom detektoru. 1996. g. razvijen je prvi multidetektor (temperatura i dim) kao pametni detektor koji koristi logiku “ILI” i “I”. Velike promjene u tehnologiji dimnih detektora nastupile su pojavom pametnih detektora. Takvi detektori dima pružali su mogućnost regulacije praga alarma preko displeja centralnog upravljačkog modula.

### 2.1.1.2.3. Laserski detektor dima

Princip rada laserskog detektora dima sličan je radu optičkog detektora, međutim umjesto led diode, laserski detektor koristi lasersku diodu. Ovi detektori dima omogućuju iznimno visoku osjetljivost na plamen, otkrivajući najranije čestice izgaranja. To se postiže kombiniranjem optičke komore u kojoj je smještena laserska dioda i precizne optičke tehnologije, što povećava osjetljivost detekcije, odnosno osjetljivost detektora dima. Komora je povezana s procesorskim sustavom čiji je zadatak filtriranje, tj. izgladivanje signala kako bi se uklonila stanja koja mogu biti uzrok neželjenih alarma. Rezultat je vrlo osjetljiv, ali stabilan detektor dima koji može postići osjetljivost od 0,07 % do 6,56 % po metru zamračenja i pruža do 100 puta višu osjetljivost od standardnog fotoelektričnog detektora dima. Svojim brzim odgovorom i preciznošću, laserski detektor dima je idealan za primjenu gdje su značajna ulaganja u instaliranu opremu npr. elektronika, telekomunikacijske sobe, računalne učionice i slično.



Slika 12: Usporedbe standardnog fotoelektričnog detektora dima i laserskog detektora dima


Što se tiče upotrebe laserskih detektora dima u sklopu brodskih vatrodojavnih sustava, zbog svoje preosjetljivosti nisu u širokoj upotrebi, eventualno se mogu instalirati u raznim brodskim prostorima gdje su smješteni skupi elektronski uređaji, a također i u raznim uredima i prostorima putničkih brodova gdje se zahtjeva veća sigurnost putnika, posade i broskog inventara.

### 2.1.1.3. Detektor plamena

Paralelno s optičkim detektorom dima razvijao se i detektor plamena. Detektori plamena su rješenje za gotovo sve primjene, kada uslijed požara dolazi do velikih gubitaka kapitalnih oprema kao što su naftovodi i plinovodi, off-shore platforme, automobilske



proizvodni objekti, zrakoplovi, brodovi, tvornice municije, nuklearna postrojenja, i gdje je rizik za osoblje visok. Ovi sustavi koriste uređaje koji odgovaraju zračenju energije vidljive ljudskom oku (od 400 do 800 nm) ili zračenja energije izvan raspona ljudskog vida obično infracrveno (IR – Infra red), ultraljubičasto (UV – Ultra violet) ili oboje, što se vidi i na slici 13.



Slika 13: Emisija energetskega spektra

Detektori plamena su osjetljivi na žar, ugljen ili stvarnu vatru dovoljne jakosti da pokrenu detektor te aktiviraju alarm. Ne postoji idealan detektor plamena koji bi mogao odgovoriti svim mogućim primjenama. Zbog moguće pogrešne procjene realnog alarma izazvanog munjom groma, iskrenjem prilikom varenja, svjetlosti sunca, upotrebom cigareta, moramo izabrati adekvatni detektor plamena da bi opravdao svoj zadatak i funkciju pravovremenog otkrivanja incidentne situacije, odnosno požara. U sljedećoj tablici prikazan je odabir tipa detektora plamena s obzirom na vrstu goriva i izvora lažnih alarma.

Tablica 4: Odabir detektora plamena s obzirom na vrstu goriva i izvore lažnih alarma.


gorivo izvori lažnih alarma	boje	propan metan butan ugljik	drvo papir plastika	benzin ulje maziva	sumpor metali	proizvodi vodika koji ne sadrže ugljik
električni luk od zavarivanja bljesak munje	UV / IR IR <sub>3</sub>	UV / IR IR <sub>3</sub>	UV / IR IR <sub>3</sub>	UV / IR IR <sub>3</sub>	UV	UV UV / IR
Gama i X zračenje	IR <sub>3</sub>	IR <sub>3</sub>	IR <sub>3</sub>	IR <sub>3</sub>	nije primjenjiv	nije primjenjiv
elektrostatički lukovi	IR <sub>3</sub> UV / IR	IR <sub>3</sub> UV / IR	IR <sub>3</sub> UV / IR	IR <sub>3</sub> UV / IR	UV	UV UV / IR
zagrijane površine	IR <sub>3</sub> UV	IR <sub>3</sub> UV	IR <sub>3</sub> UV	IR <sub>3</sub> UV	UV	UV

Izvor: Izradio autor prema <http://www.thermocense.com/>

### 2.1.1.3.1. UV detektor plamena

Ultraljubičasti (UV) detektori rade s valnim duljinama kraćim od 300 nm. Kod UV detektora plamena, kako bi se smanjili lažni alarmi, kašnjenje iznosi 2 – 3 sekunde i često je uključen u dizajn UV detektora plamena. Ovi detektori otkrivaju požar i eksploziju u krugu 3 – 4 milisekunde zbog UV zračenja emitiranog u trenutku njihova zapaljenja [14].

UV detektor plamena klase 1 definirane standardom EN54 dizajniran je tako da otkrije plamen veličine 0,1m<sup>2</sup> ili jasan plamen od 0,25 m<sup>2</sup> na 25 m. Isto tako, UV detektor plamena će otkriti vatru na udaljenosti do 30 metara, ako je veličina plamen proporcionalno veća, u ovome slučaju 0,3 m<sup>2</sup> na 30 m. UV detektor plamena bi trebao biti smješten na obodu sobe, izravno usmjeren na područje mogućeg predviđenog plamena ili u središtu područja koje se štiti kao npr. na brodu u brodskoj strojarnici iznad glavnog stroja.




Slika 14: Načini smještaja UV detektora plamena


Ako detektori ne mogu obuhvatiti cijela područja koja se zaštićuje, tada se može prema potrebi dodati jedan ili više dodatnih detektor plamena. Na UV detektor plamena ne utječu uobičajeni izvori svjetlosti, ali bi trebao biti postavljen tako da dnevna svjetlost nije u djelokrugu rada detektora.

Ukoliko se detektor instalira na stropu prostora detekcije, odnosno u sredini okomito iznad područja koje treba štititi te ako dođemo do zaključka da jedan detektor plamena nije dovoljan za pokrivanje predviđenog prostora detekcije, dodajemo sljedeći detektor po potrebi. Područje detekcije ovisi o visini smještaja detektora iznad mogućeg izvora plamena.

UV (ultraljubičasti) detektor plamena tip Apollo klase 1, ima 90° konusno vidno polje ili 45° na obje strane, gledano od središnje linije. Ako je maksimalna visina stropa 20 m, i ukoliko je detektor okomit na pod odnosno na predmet detekcije na visini od 10 metara tada će djelokrug detekcije biti kružne površine polumjera 10 m, odnosno dijametra 20 m, kao što se vidi na sljedećoj slici.



Slika 15: Prikaz stropne ugradnje UV detektora plamena

Izvor: Izradio autor prema [www.apollo-fire.cn](http://www.apollo-fire.cn)

Slika 16: Kut gledanja UV detektora plamena tipa Apollo

Izvor: Izradio autor prema [www.apollo-fire.cn](http://www.apollo-fire.cn)

#### 2.1.1.3.2. IR detektor plamena

Općenito, detektori plamena rješenja su za požare koji mogu rezultirati velikim gubitkom kapitalne opreme i kada je rizik za osoblje vrlo visok. Tu se misli na naftovode i plinovode, kućišta turbina, off-shore platforme, autoproduktivne objekte, zrakoplove, brodove, nuklearna postrojenja i drugo. Detektori plamena su osjetljivi na užareni žar ili na stvarni plamen s energijom dovoljnog intenziteta i spektralne kvalitete za pokretanje alarma detektora.

Infracrveni detektori (IR) plamena rade u infracrvenom spektralnom pojasu. Lažni alarmi mogu biti posljedica uzrokovana ostalim vrućim površinama u području kontrole požara. Tipičan frekvencija IR detektora plamena je frekvencija osjetljiva na 4,4 mikrometar raspona, uz vrijeme odziva 3 – 5 sekundi.

Danas kao izvedba, koriste se IR detektori plamena s jednim infracrvenim senzorom, s dva infracrvena senzora, gdje se zbog lažnih alarma, detektor alarmira tek u slučaju da se oba infracrvena senzora aktiviraju. Nadalje, postoje i najnovije izvedbe s tri infracrvena senzora, za prostore ili objekte u kojima se inzistira na boljoj i većoj zaštiti od lažnih alarma.



Slika 17: Vrste IR detektora plamena

Izvor: [www.consilium.se](http://www.consilium.se)


U sljedećoj tablici (5) prikazane su udaljenosti za detektor plamena Salwico tip AC-IR3Fq na kojima se postižu najbolji rezultati kontrole zaštićenog područja.

Tablica 5: Klasa (prag) osjetljivosti AC-IR 3Fq detektora plamena


Klasa osjetljivosti	Klasa 1 / opseg	Klasa 2 / opseg	Klasa 3 / opseg
Osjetljivost	Visoka sve do 25m	Srednja sve do 17m	Niska sve do 12m

Izvor: Izradio autor prema [www.consilium.se](http://www.consilium.se)

Inače AC-IR 3Fq je infracrveni detektor plamena s trostrukim senzorom gdje svaki senzor radi na određenoj frekvenciji. Sam detektor proizveden je pomoću najnovije tehnologije. Dok jedan senzor recimo A, mjeri vrući ugljični dioksid plamena specifične valne duljine, senzori B i C istovremeno mjere smetnje zračenja u blizini valne duljine. Ova inteligentna tehnika mikroprocesorima i algoritmima obrađuje mjereni signal pomoću kojeg se postiže odlična pouzdanost detekcije, zadržavajući najviši imunitet na smetnje zračenja i Sunčeve svjetlosti.



Slika 18: Kut i visina prijama AC-IR 3Fq detektora plamena

Izvor: Izradio autor prema [www.consilium.se](http://www.consilium.se)

Slika 19: Područje pokrivenosti i klasa (prag) osjetljivosti AC-IR 3Fq detektora plamena

Izvor: Izradio autor prema [www.consilium.se](http://www.consilium.se)

### 2.1.1.3.3. UV/IR detektor plamena


Kad je optički UV senzor integriran s IR senzorom, tzv. *dual band* detektor dobili smo detektor osjetljiv na UV i IR emitirana zračenja plamena. Kombinirani UV/IR detektor plamena ima osobinu povećane otpornosti preko UV detektora, a uz rad na umjerenim brzinama pogodna je za vanjsku i unutarnju upotrebu.

UV/IR Apollo detektor plamena istovremeno koristi ultraljubičasto (185 – 260 nm) i infracrveno (0,75 – 2,7  $\mu\text{m}$ ) zračenje na 1 – 15 Hz kako bi se otkrila sva treperenja plamena, uključujući, i one nevidljive golim okom, npr. ona iz vodika požara. Detektor ima jedan UV i IR senzor na različitim valnim duljinama kako bi otkrili razliku između plamena i sumnjivih izvora zračenja. Lažne uzbune zbog električnog pražnjenja munje ili zavarivanjem i treperenja sunca, minimizirani su kombinacijom UV/IR signala.

#### 2.1.1.4. Ručni javljači

Ljudi često mogu otkriti vatru mnogo prije automatskih detektora požara. Stoga su ručni javljači kao važne komponente sustava za dojavu požara bitne u osiguravanju objekata, inventara i zaštiti ljudskog života, kako bi se osigurala pravovremena evakuacija u slučaju požara. Svi ručni javljači trebaju odgovarati standardu EN54-11, tipa A, koji nakon slomljenog lomljivog elementa (stakla) automatski aktivira alarm.

Sve vrste ručnih javljača imaju isti način aktiviranja, osim nekih koji imaju dodatnu specijalnu funkciju kao što su ručni javljači za aktivaciju sustava vodene magle, gdje se ručni javljači vodene magle štite zaštitnim poklopcem, radi sigurnosti da ga ne može bilo tko aktivirati. Također, ručni javljači razlikuju se i u bojama. Crvena boja je standard za požarni sustav, dok se plava boja koristi za sustav vodene magle.



Slika 20: Ručni javljači

Izvor: [www.consilium.se](http://www.consilium.se)


Vrlo je bitno da osoba koja aktivira ručni javljač bude svjesna aktivacije ručnog javljača. Pravila u skladu sa standardima razvijenih zemalja kažu, da se alarm kao posljedica aktiviranja ručnog javljača mora javiti odmah, bez vremenskog kašnjenja. Odabir lokacija ručnih javljača moraju biti uočljive i lako pristupačne bez prepreka i dobro osvijetljene.

Prema SOLAS-u ručni javljači se obavezno postavljaju na putovima evakuacije ili na izlazima iz prostorija, u hodnicima nadgrađa, prostorima za razonodu i rekreaciju, predvorjima, prostorijama površinski većim od 150 m<sup>2</sup>, svim prostorima brodske strojarnice, raznim mjestima upravljanja vitalnih brodskih sustava, prostorijama posebne kategorije, na ulazima kao što su ulazi u brodsku strojarnicu, nadgrađe prostora tereta, prostore za prijevoz automobila, vagona i ostalih transportnih sredstava.

### 2.1.2. Optimizacija rasporeda detektora vatrodojavnog sustava

Osnovna pravila u postupku postavljanja detektora su njihov pravilan raspored, zbog čega se pravilan raspored detektora smatra vrlo bitnim čimbenikom pri projektiranju zaštite nekog objekta ili šticeenog prostora. Kad je postavljanje detektora gusto i brzina reakcije detektora te vatrodojavnog sustava uopće, sigurno je brža, ali i poskupljuje sustav. Smatra se da je dobar onaj projekt kod kojeg je raspored i gustoća postavljanja detektora takva da optimalno zadovoljava i omogućuje brzu detekciju uz istovremenu prihvatljivu cijenu cjelokupnog sustava dojava požara. Gustoća postavljanja zavisi od veličine šticeenog prostora, uvjetima koji vladaju u šticeenom prostoru i predviđenog rizika požara.

U prostorima s horizontalnim stropom, rastojanje između detektora dima ne smije biti veće od 11 m, dok za temperaturne detektore 9 m. Također se podrazumijeva da je maksimalna pokrivenost prostora dimnog detektora 74 m<sup>2</sup>, temperaturnog 37 m<sup>2</sup>.



Slika 21: Površina pokrivenosti detektora


Pravilo SOLAS konvencije definira maksimalni razmak između detektora, vidljivo iz tablice 6:

Tablica 6: Pravila postavljanja detektora temperature i dima

TIP DETEKTORA	MAKSIMALNA POKRIVENOST	MAKSIMALNA UDALJENOST	RADIJUS POKRIVENOSTI
TEMPERATURNI DETEKTOR	37 m	9 m	4,5 m
DIMNI DETEKTOR	74 m	11 m	5,5 m



Tamo gdje prostor omogućava detektori se postavljaju u redove. U brodogradnji to je slučaj s brodovima za prijevoz automobila, kamiona ili vagona. Optimalno razmak između redova i samih detektora treba biti što pravilnije, odnosno po principu kvadratne raspodjele.



Slika 22: Idealna površina nadziranja dimnih detektora i detektora temperature

Potrebni broj detektora  $n$  u idealnoj pravokutnoj prostoriji s ravnim stropom površine  $P$  izračunava se pomoću izraza:

$$n = \frac{P}{S} \quad (2.8)$$

gdje je  $S$  površina pokrivenosti jednog detektora (68 m<sup>2</sup> – detektori dima, 44 m<sup>2</sup> – detektori temperature).

Što znači da za pokrivenost nadzirane površinu od 680 m<sup>2</sup> treba 10 detektora dima, dok istovremeno za istu površinu je potrebno otprilike 15 detektora temperature.

Ponekad konfiguracija prostorije, kao na primjer na brodu, onemogućava idealan raspored, pa treba težiti što većem optimumu. Takav optimum izvodi se kombinacijom više određenih tipova detektora. Najčešća kombinacija uključuje detektore dima, temperature i plamena. Svrha dobrog rasporeda detektora na brodovima je omogućavanje pravovremene i brze detekcije požara.

Kod kosih stropova međusobno rastojanje se povećava za svaki stupanj, odnosno do najviše 25 % nagiba, što znači da ako je nagib 10 %, rastojanje se može povećati za 10 %. U prostorima gdje su stropovi kosi, detektori se postavljaju tako da je razmak između



-----

detektora veći na nižim visinama i obratno, manji na većim visinama stropa. Takvi primjeri nagiba postoje na brodovima s podiznim palubicama, kao i pojedinim prostorima strojarnice. Lociranje požarnog incidenta povećava se brojem detektora. Znajući da produkti sagorijevanja i toplina dolaze do najbližeg detektora, povećavanjem njihovog broja raste i brzina otkrivanja vatre ili dima.

### 2.1.3. Grupiranje detektora vatrodojavnog sustava u zone

U konvencionalnim vatrodojavnim sustavima linije postavljanja detektora predstavljaju i zone detekcije, u kojima je lako otkriti uzročno mjesto nastanka požara. Zone moraju pružiti otkrivanje lokacije alarma brzo i učinkovito. Bitno je znati da kod konvencionalnog sustava dojava požara, jedna linija detekcije odgovara jednoj zoni detekcije. U konvencionalnom sustavu linija (zona) može sadržati maksimum 30 dozvoljenih senzora, kao na primjer po britanskom standardu. Pravilno zoniranje detektora i ručnih javljača vatrodojavnog sustava pospješuje brzinu otkrivanja mjesta podrijetla požarnog incidenta. Ta pravila su najčešće [13]:

- površina koja se štiti jednom zonom detekcije ne smije premašiti 2000 m
- razdaljina između ručnih javljača unutar vizualnog pokrivanja prostora jedne zone detekcije, ne smije biti veća od 30 m
- ako određena zona štiti više prostora tada one moraju biti jedna pored druge
- postavljanje ručnih javljača požara mora biti u zasebnoj zoni, međutim pojedina klasifikacijska društva dopuštaju da se detektori i ručni javljači stave u iste zone detekcije. Aktivacija ručnih javljača smatra se sigurnim znakom alarmiranja požara
- ukoliko zona detekcije štiti više od jednog prostora, tada je granica zone ujedno i granica požarnog sektora. Požarni sektor kao cjelina na brodovima je odvojena od ostalih prostora protupožarnim vertikalama sprječavajući širenje požara iz jednog sektorskog prostora prema drugima. Dozvoljeno je da dvije zone detekcije mogu štititi jedan sektorski prostor, ali nije dozvoljeno da dva sektora štite jednu zonu. Također, nije dozvoljeno da pojedine dijelove dviju ili većeg broja zona štiti jedan sektor. Broj detektora spojenih u jednoj zoni ograničeni su određenim faktorima:
  - uvjetima SOLAS-a

- 
- maksimalnom strujom detektora u normalnom radu (bez alarma)
  - pravilnim projektiranjem alarmnih vatrodojavnih brodskih sustava.

SOLAS određuje broj zona i pravila vatrodojavnih sustava koja glase [4]:

- jedna zona detekcije ne smije pokrivati više od jedne palube, osim zatvorenog stubišta
- kod brodova za prijevoz putnika zona pokrivanja ne smije biti više od jedne palube, ne smije prelaziti iz jedne vertikalne protupožarne zone u drugu i ne smije pokrivati istovremeno obje strane broda
- zona broetskog nadgrađa (nastambe, društvene prostorije, kontrolne stanice) mora biti odvojena od prostora strojeva i obratno
- zona broetskog nadgrađa (nastambe, društvene prostorije, kontrolne stanice) mora biti odvojena od brodske strojarnice i obratno.

## **2.2. Osnovne karakteristike i vrste vatrodojavnih alarmnih sustava**

Tehnološki razvoj vatrodojavnih sustava usko je povezan s tehnološkim razvojem detektora požara. Slijedom toga međunarodna zajednice uz ekološku zaštitu zahtjeva i što veću zaštitu ljudi i imovine. Upravo zato novi brodski sustavi vatrodaje uz pomoć ugrađene i implementirane najnovije tehnike i tehnologije pružaju trenutno najveću moguću sigurnost pravilnog rada sustava gdje se podrazumijeva u prvom redu pravovremena detekcija incidentne situacije, a potom i ostale funkcije sustava koje slijede nakon detekcije


Neke funkcije procjene i odlučivanja osim u centralnoj jedinici vatrodojavnog sustava, izvode se u samom detektoru. Sam kronološki razvoj vatrodojavnih sustava može se pratiti kroz povijest pojedinog proizvođača opreme sustava.

### **2.2.1. Konvencionalni vatrodojavni alarmni sustav**

Tehnološka primjena i rad konvencionalnih vatrodojavnih sustava bazirao se na principu nadziranja određenog broja petlji na koje su se spojili i projektirani broj konvencionalnih vatrodojavnih detektora. Svi detektori određene linije napajali su se s te iste linije. Aktiviranjem jednog detektora određene linije, centralni sustav vatrodaje javlja signal alarma odgovarajuće zone alarma, odnosno pripadne nadzorne linije. Kao problem

detekcije kod konvencijalnog vatrodojavnog alarmnog sustava bila je nemogućnost otkrivanja točnog mjesta požara, odnosno koji je detektor u alarmu.

Što točnije otkrivanje mjesta nastanka požara, jedan je od osnovnih funkcija konvencijalnog alarmnog vatrodojavnog sustava. Standardima je ograničen broj detektora jedne nadzirane linije. Sve članica IEC-a dužne su bile primjenjivati standard EN54, prema kojem na jednoj konvencionalnoj liniji (zoni detekcije) smije biti spojeno najviše 30 detektora.



Slika 23: Primjer zona detekcije s konvencionalnim petljama

Izvor: Izradio autor prema [www.cosilium.se](http://www.cosilium.se)

Detektori požara bilo konvencionalni ili adresabilni koriste iste principe detekcije požara kao:


- mjerenje prisutnosti dima;
- mjerenje temperature okoline;
- uočavanje treperenje plamena;
- izvor topline.

Alarmna vatrodojavna centrala nadzire linije detektora požara, odnosno detektore nadzirane zone. U slučaju prekida linije nadzora ili kratkog spoja linije, iz funkcije ne smije ispasti više od jedne zone, tj. najviše 30 konvencionalnih detektora. Da bi konvencionalni sustav mogao registrirati prekid linije u konvencionalnom sustavu na kraju linije se postavlja završni otpornik koji omogućuje kontrolu cijelosti i ispravnosti linije (zone).

### 2.2.2. Adresabilni vatrodojavni alarmni sustav

Ugrađujući u detektor vatrodojave određeni funkcionalni sklop koji komunicirajući s vatrodojavnom centralom šalje svoju adresu (broj koji određuje točno mjesto na brodu), nastaje adresabilni vatrodojavni sustav. Ovaj sustav omogućio je točno određivanje lokacije nastanka požarnog incidenta, zbog čega je dozvoljeno na liniju spojiti i više od trideset detektora. Kod adresabilnog vatrodojavnog sustava propis standarda EN-54 kaže da u jednoj petlji ne smije biti više od 128 adresabilnih detektora. Slika 28 prikazuje pravilan način izvođenja petlje gdje ulaz i izlaz petlje završava u vatrodojavnom sustavu, odnosno na modulu kontrole petlje. U slučaju jednostrukog prekida određene vatrodojavne petlje detektori i dalje rade, jer napajanje petlje, odnosno komunikacija petlje dolazi sa obje strane petlje. Također, nakon svakih maksimalno 20 do 30 detektora ugrađuje se izolator čija funkcija je detektiranje kratkog spoja. Detekcijom kratkog spoja između dvaju izolatora istovremeno, isključit će se linija između njih i prestanak rada detektora isključenog dijela linije do otklanjanja kvara.

Mikroprocesor kao najvažniji elektronički sklop alarmnog vatrodojavnog sustava preuzima programske komande i naredbe i na osnovi njih obrađuje podatke. Mikroprocesor, kao centralna procesna jedinica računala sastoji se od logičkih sklopova za izvršavanje aritmetičkih i logičkih operacija i upravljačke jedinice.



Slika 24: Adresabilna petlja s adresiranim jedinicama detekcije

Izvor: Izradio autor prema [www.autronicafire.com](http://www.autronicafire.com)

Adresabilni sustav u odnosu na konvencionalni ima višestruke prednosti [17]:

- točno locira detektor alarm ili kvar detektora
- ima pridruživanje teksta detektoru ili određenoj zoni
- pridružuje ispisu alarma i vrijeme događaja
- registrira događaje, uključujući i postupak operatera (prihvatanje raznih signala), ispis na printeru ili zapis u ugrađenoj memoriji (koji se može naknadno pogledati i provjeriti)
- ima jednostavnije, i kod većih sustava jeftinije ožičenje
- sustav je manjih dimenzija sa smanjenom potrošnjom.

Adresabilni i konvencionalni vatrodojavni sustavi vizualno koriste slične detektore. Razlika je u tome što adresabilni detektor ima ugrađeni adresabilni sklop unutar detektora, pomoću kojeg se upisuje adresa detektora, no način detekcije požara i jednog i drugog sustava u principu je isti, tj. senzor detektora sustava daje i šalje informaciju POŽAR.

### **2.2.3. Analogno-adresabilni vatrodojavni alarmni sustav**

Napredniji sustav od adresabilnog je analogno adresabilni-vatrodojavni sustav. Ta prednost se očituje u načinu obrade informacije dobivene od analogno-adresabilnog detektora. Analogno-adresabilni detektor je senzor određene fizikalne veličine koji na upit vatrodojavne centrale šalje pored svojeg broja i tipa detektora, također i informaciju o izmjerenoj vrijednosti. Analogno-adresabilni detektor ima mikroračunalo sa A/D konverterom, koji analognu mjernu vrijednost pretvara u digitalnu i po određenom protokolu šalje centralnom uređaju. Centralni uređaj vatrodojavnog sustava uspoređuje signal pojedinog senzora sa referentnim uzorkom „otiskom požara“ koji je memoriran u memoriji centralnog uređaja. U slučaju da se uoči diskrepancija između signala, centralni uređaj generira alarm, istovremeno uključujući svjetlosnu signalizaciju. Kontinuirano mjerenje omogućuje korištenje međustanja, odnosno između normalnog stanja i alarma. Nedefinirano stanje zvano predalarmno ukazuje da još uvijek nije nastupilo stanje alarma.

Informacija predalarma korisna je iz dvaju razloga:

- obavještava da stanje nije normalno
- obavještava na moguću zaprljanost detektora dima.

-----

Mogućnost programiranja osjetljivosti svakog detektora, njegovog praga predalarma i alarma, omogućuje korištenjem istog tipa detektora u različitim uvjetima različitih prostora i različitih temperatura. S centralnog uređaja preko displeja u svakom trenutku moguće je dobiti informaciju o analognoj vrijednosti određenog detektora. Uz testiranje detektora s centralnog uređaja, centralna jedinica omogućuje uključivanje lokalne svjetlosne signalizacije i aktiviranje odabranih izlaznih funkcija.

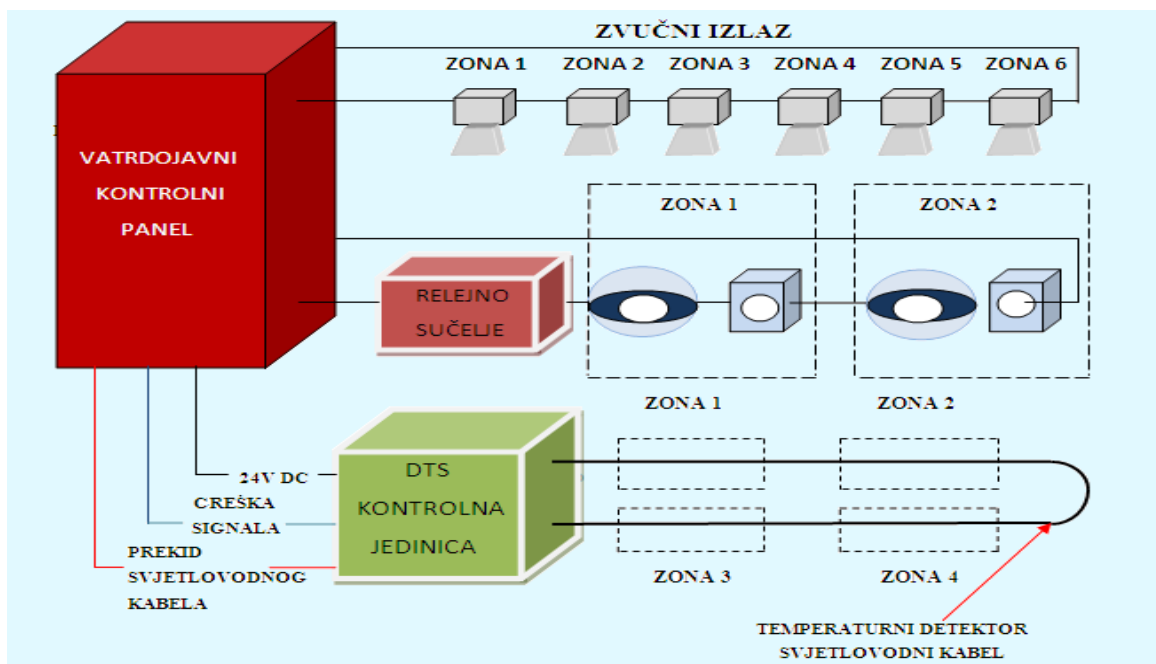
Moderni sustavi omogućuju kompletan nadzor i upravljanje s jednog ili više mjesta, omogućujući brz pregled nastalih događaja (alarm, predalarm, kvar, isključenje). Korištenjem ponavljača različitih signala (*repeater panels*) kao dodatni uređaj, požarni sustav omogućuje kompletan prikaz događaja istovremeno na više brodskih mjesta.

#### 2.2.4. Vatrodojavni sustav zasnovan na upotrebi svjetlovodnog kabela

Jedan od najsuvremenijih vatrodojavnih sustava zasnovan na uporabi svjetlovodnog kabela kao detektora je sustav koji koristi optički vodič s laserskim izvorom svjetla. Rad detektora baziran je zbog promjena parametara uslijed deformiranja optičkog vodiča. Uzrok deformacije vodiča je širenje cijevi punjene voskom zbog rasta temperature okoline. Isto tako uslijed hlađenja optički vodiči cijevi punjenih voskom vraćaju se u prvobitni pravilan oblik.

Svjetlovodni kabel sastoji se od cijevi punjene sa voskom u kojem je smješten optički vodič. Sve zajedno zaštićeno je metalnom cijevi, zbog čega je kabel dosta velikih gabarita. Da bi se moglo točno odrediti mjesto nastanka požara ili zone požarnog incidenta uz smjer i brzinu daljnjeg napredovanja, prije same uporabe potrebno je izvršiti sektorizaciju svjetlovodnog kabela. Ovakvi sustavi zasad najviše se upotrebljavaju u cestovnim i željezničkim tunelima, zračnim lukama, komunalnim tunelima, rafinerijama [18].

Sljedeća slika prikazuje svjetlovodni linearno-temperaturni detektor koji funkcionira preko modulskog distributera temperaturnog senzora ( DTS ), koji koristi optička vlakna kao detektor. Ovaj sustav zvan *firelaser*, može ispitati temperaturu u svakom intervalu od 1 metra duž instaliranog optičkog kabla do 4 km po krugu s temperaturom rezolucije boljom od 1 °C . Sustav pruža niz alarmnih stanja kao što su maksimalne temperature praga, temperatura stope rasta praga i odstupanja temperature.



Slika 25: Vatrodojavnih sustava zasnovan na upotrebi svjetlovodnog kabela

Karakteristike sustava sa svjetlovodnim kabelom su [19]


- jednostavnost instalacije
- pouzdano i brzo otkrivanje temperature LHD (Linear Heat Detection) tehnologijom
- nije osjetljiv na elektromagnetski utjecaj, na vlagu, na promjene temperature uslijed vremenskih uvjeta, na vibracije
- otporan je na agresivne kemikalije, na prašinu i nečistoću, mehaničke udarce, vodu
- vlakno je potpuno pasivni senzor i ima vrlo dug vijek trajanja
- nema elektronike ili pokretne dijelove
- mjerenja temperature su predviđene preko ukupne dužine osjetilnog kabela.

Trenutno na tržištu kabel koji se koristi kao svjetlovodni linearno-temperaturni detektor je vrlo skup, zbog čega još nije u uporabi u brodogradnji, iako bi bio idealan kod brodova za prijevoz automobile s više paluba. Moguće je da u budućnosti ova vrsta svjetlovodnog detektora u obliku vatrodojavnog integriranog kruga bude znatno jeftinija te se koristi i na brodovima. Optički senzorski kabel uz mjerenje maksimalne zadane temperature mjeri i temperaturnu promjenu.

### 2.2.5. Bežični vatrodojavni sustav

Tradicionalno, vatrodojavni sustavi su dizajnirani da pomoću kabela povezuju detektore vatrodojave s centralnom jedinicom. Korištenje kabela je skup izbor, a tu se podrazumijeva da je i cijeli sustav: instalacija vodova, različiti konektori, napajanja i transformatori, potrošnja energije, skup. Bežični vatrodojavni sustav alternativa je klasičnima. Sustav nudi pouzdane bežične veze upravljačkog modula pomoću u potpunosti nadziranih bežičnih signala, umjesto žica.

Isto tako, uređaji koji zahtijevaju snagu, poput detektora dima, temperature, detektora plamena i svih ostalih perifernih uređaja u sklopu vatrodojave, zahtijevaju skupa napajanja, jer uslijed dužine kabela uzrokuju pad napona. Budući da bežični sustav za otkrivanje požara ne zahtijevaju kabel za spajanje između centralnog uređaja i opreme za nadziranje, bežični sustav može eliminirati troškove povezane s kabelom. Centralni bežični odašiljač u potpunosti nadzire periferne uređaje. Bežični centralni uređaj redovito preko odašiljača šalje poruke prema opremi sustava, odnosno detektorima, te je sustav neprestano svjestan stanja svakog detektora preko njegovog odašiljača. Odašiljači imaju ulogu priopćavanja svake statusne promjene [20].



Slika 26: Bežični vatrodojavni sustav



-----

Današnja moderna tehnologija omogućuje izradu vrlo ozbiljnih stabilnih vatrodojavnih adresabilnih sustava korištenjem bežične tehnologije. Komunikacija između bežične vatrodojavne centrale i bežičnih detektora sigurna je koliko i kod vatrodojavnih sustava spojenih kabelima, jer bežični sustav radi s dvosmjernom komunikacijom između detektora i panela preko odašiljača, osiguravajući kontinuiranu i pravovaljanu dojavu nastalih grešaka, kao što je greška niskog napona, greška elektronike, greška u komunikaciji, zaprljanost detektora ili alarmnog stanja.

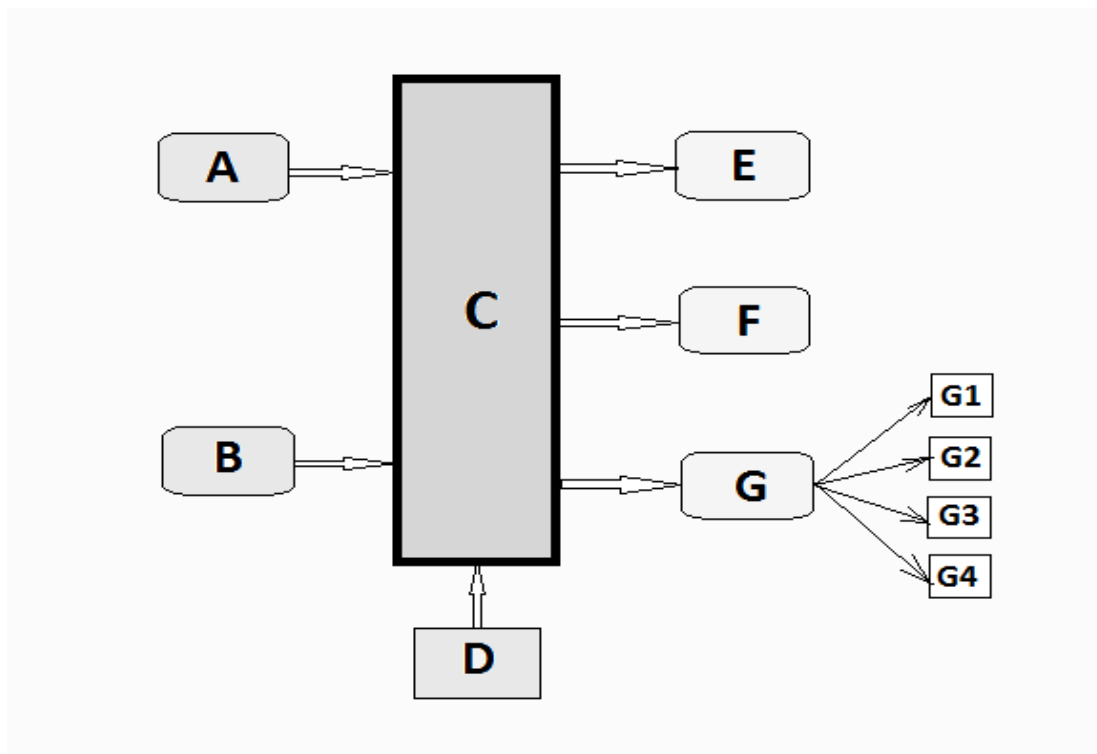
## 2.3 Struktura broorskoga vatrodojavnog sustava

Današnji moderni broski vatrodojavni sustavi omogućavaju kompletan nadzor i upravljanje s centralnog mjesta, u slučaju broda s komandnog mosta. Međutim, što se tiče brodova za prijevoz putnika, 2010. godine stupila su na snagu neka nova pravila.

Sam sustav brodske vatrodojave omogućuje brzi i pregledni prikaz cjelokupnog broorskog vatrodojavnog sustava i djelovanje sustava u kojima je nastao alarm, predalarm, kvar, isključenje i drugo. Korištenjem dodatnih uređaja kao što je ponavljač se omogućuje kompletan prikaz događaja u sustavu na više mjesta.

Alarmni vatrodojavni sustavi sastoje se od komponenti prikazanih na slici 32 pri čemu je:

- A. – detektori požara;
- B. – ručni javljači požara;
- C. – centralne vatrodojavna jedinica (ulazno-izlazni modul)
- D. – uređaj napajanja sustava detekcije požara;
- E. – uređaj za zvučnu i svjetlosnu signalizaciju;
- F. – paralelni pokazivač događaja (alarm, kvar)
- G. – uređaj za aktiviranje izvršnih funkcija sistema, kao što su:
  - G1 – daljinsko isključivanje ventilacije
  - G2 – zatvaranje protupožarnih vrata
  - G3 – zatvaranja protupožarnih klapni na ventilacijskim ili klimatizacijskim sustavima
  - G4 – daljinski start sustava za raspršivanje vodene magle TD.



Slika 27: Komponente vatrodojavnog sustava

## 2.4 Osnovne funkcije broškoga alarmnog vatrodojavnog sustava

Zadatak centralne jedinice kao najvažnije komponente cjelokupnog vatrodojavnog sustava detekcije i alarmiranja požarnih incidenata je da uz komunikaciju i napajanja detektora stabilnim neprekidnim naponom (napajanje 220 VAC s glavne rasklopne ploče i pomoćno napajanje s baterija 24 VDC, prima informaciju o normalnom stanju cjelokupnog sustava, alarma, ispravnosti linija, zamjeni vatrodojavnih detektora, prekidu ili kratkom spoju određene petlje, te da dobivenu informaciju signalizira na centrali, uz istovremeno omogućavanje izvršne funkcije koja se od nje zahtijeva. Napredak tehnike gašenja požara na brodu pomoću vatrodojavnih sustava uvjetovao je također funkcionalnu sposobnost alarmnog sustava vatrodojave i to na [21]:

- sposobnost automatskog lociranja žarišta požara
- sposobnost automatskog ocjenjivanja veličina požara i stupnja ugroženosti
- sposobnost automatske primjene adekvatnog odgovora
- učinkoviti sustav dijagnostike
- centralizirano i osjetljivo odlučivanje pomoću broškog integriranog sustava.

Uz prethodno navedene sposobnosti svaki broski vatrodojavni sustav dužan je obavljati i sljedeće funkcije [4]:

- kontinuirano sakupljati informacije o stanju detektora požara
- komunikacijom prenositi informacije od centralne jedinici do detektora i obratno
- primljene informacije obrađivati i donositi zaključke
- odrediti mjesto nastanka požara
- ako je potrebno automatski uključiti sustave za gašenje požara (vodena magla, vodeni mlaz, halon, CO<sub>2</sub>)
- isključivati klimatizaciju i ventilaciju
- automatski zatvarati požarna vrata
- obavljati kontrolu glavnog i rezervnog sustava za napajanje
- signalizirati greške vatrodojavnog sustava na centralnoj jedinici, kratki spoj, petlji te sklopovskih i programskih modula.

## **2.5. Pouzdanost i raspoloživost broorskoga alarmnog vatrodojavnog sustava**

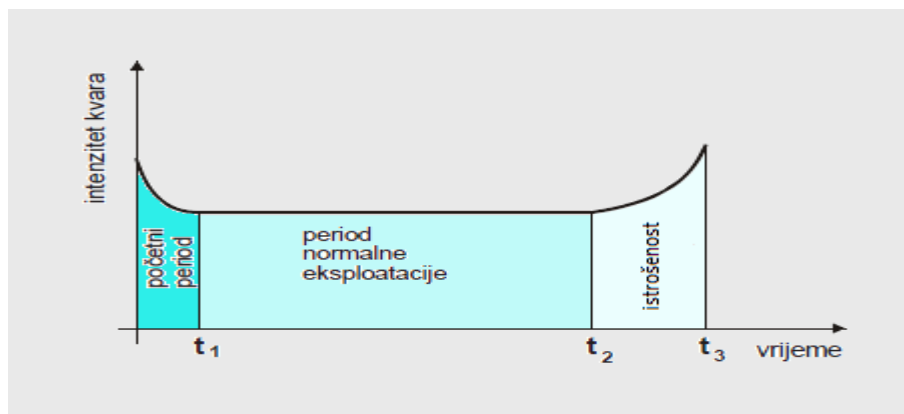
Ispravnost broorskog vatrodojavnog sustava povećava razinu sigurnosti života na brodu. Kako znamo da je glavna zadaća vatrodojavnog sustava brzo otkrivanje dima ili vatre, vrlo je važno biti siguran u pouzdan vatrodojavni sustav, tj. u funkcionalnu ispravnost komponenata broorskog vatrodojavnog sustava.

### **2.5.1. Pouzdanost broorskoga vatrodojavnog sustava**

Pouzdanost  $R(t)$  je vjerojatnost da će neki uređaj, u našem slučaju vatrodojavni sustav, zadovoljavajuće raditi unutar određenog vremena ( $t$ ), ispravno bez kvara, odnosno pouzdanost je određena ukupnim brojem kvarova vatrodojavnog sustava unutar predviđenog vremenskog razmaka.

Današnja tehnika pouzdanosti može unaprijed odrediti vijek trajanja vatrodojavnog sustava ili njegovih komponenata. Srednje vrijeme kvara moguće je unaprijed izračunati isto kao i srednju vrijednost kvara, što je vrlo bitno pri održavanju broorskog vatrodojavnog

sustava u eksploataciji. Uz to, pouzdani vatrodojavni sustav mora biti u mogućnosti svaki kvar pravovremeno signalizirati. Dijagram intenziteta kvarova tijekom radnog vijeka nekog uređaja prikazan na slici 28.



Slika 28: Funkcija intenziteta kvarova

Slika 28: prikazuje dijagram intenzitet kvara u jedinici vremena, tj. tri faze kvarova i to:

- prva faza – početni period rada ( $t_1$ )
- druga faza – period redovne eksploatacije sustava ( $t_2 - t_1$ ) i
- treća faza – istrošenost sustava i dijelova sustava ( $t_3 - t_2 + t_1$ ).

U prvoj fazi tijekom ispitivanja sustava i njegovih komponenata, te puštanja u probni rad, kvarovi se pojavljuju češće uz tendenciju postepenog smirivanja, uz otklanjanje bilo tvorničkih pogrešaka ili pogrešaka tijekom montaže. Druga faza, odnosno standardni radni vijek kroz eksploataciju sustava u pravilu je očekivana faza s najmanje kvarova gdje dolazi do isticanja pouzdanosti sustava. Nakon odrađenog zacrtanog radnog vijeka sustav i njegove komponente polako gube sposobnost pravilnog rada te sustav postaje nepouzdan, što iziskuje zamjenu dotrajalih komponenata.

Uz periodično testiranje vatrodojavnog sustava, koje se na brodu obavlja najmanje jedanput na godinu, ispravnost vatrodojavnog sustava povremeno ispituju i registarska društva nosioca zastave, radi stjecanja certifikata ispravnosti sustava i klase broda, a u skladu s međunarodnim standardima i pravilima. Detektori temperature ispituju se opremom koja zagrijava zrak na određenu alarmnu temperaturu, dok detektori dima sprejom koji sadrži čestice aerosola odgovarajuće gustoće (Slika 29).



Slika 29: Pribor za testiranje detektora vatrodojavnog sustava

Izvor: [www.consilium.se](http://www.consilium.se)

Vrlo je važno napomenuti da lučke vlasti bilo koje države imaju pravo tražiti testiranje ispravnost vatrodojavnog sustava, te u slučaju neispravnosti zabraniti uplovljavanje broda u luku odredišta.

#### **2.5.1.1. Povećanje pouzdanosti brodske vatrodojavne sustava kod putničkih brodova metodom redundancije**

Izgradnjom sve većih putničkih brodova u zadnjem desetljeću, uz povećanje broja putnika, narasla je zabrinutost s aspekta rizika sigurnog povratka u luku kako broda tako i putnika. Slijedom toga tim Međunarodne pomorske organizacije (IMO), odnosno Odbor za pomorsku sigurnost na 82. sjednici krajem 2006, preispitao je i raspravljao o sigurnosti putničkih brodova u izvanrednim situacijama. U svrhu poboljšanja, odnosno stvaranja novih koncepata brodskih sustava, pa tako i sustava dojave požara koji će to pružiti, donesene su izmjene i dopune novih SOLAS propisa, II-1/8-1, II-2/21 i II-2/22, za nove brodove duljine od 120 metara koji imaju tri ili više požarnih zona, a početkom primjene 2010.g. Izmjene se odnose na redundanciju brodskih sustava uzrokovanih pravilima sigurnog povratka broda i putnika u luku, koja pruža sigurnost i sposobnost sustava da nastavi svoju funkciju izbjegavanja zastoja i onda kada neka od komponenata u lancu toga sustava po novim propisima zataji.

SOLAS propisi II-1 / 8-1, II-2/21 i 22 izmijenjeni i dopunjeni utvrđuju tri scenarija od kojih su dva vezana upravo za sustav brodske vatrodojave i to [23]:

- dostupnost bitnih sustava za potporu sigurnog povratka broda u luku nakon nezgode uzrokovane požarom, u skladu sa SOLAS regulacijom II-2/21
- i dostupnost bitnih sustava za potporu brodskoj evakuaciji nakon incidenta izazvanog požarom, u skladu sa SOLAS regulacijom II-2/22.

### 2.5.1.2. Pouzdanost sistema napajanja broorskoga vatrodojavnog sustava

Sustav napajanja energijom za broski vatrodojavni sustav mora biti pouzdan, stabilan kao što treba biti i vatrodojavni sustav i njegova funkcionalnost, odnosno raspoloživost sustava ne smije ovisiti o reduciranom napajanju.

Pouzdanost, a uz to i raspoloživost broorskog napajanja (glavno i pomoćno napajanje 220V AC) nije i ne smije biti jedini izvor napajanja cjelokupnog alarmnog vatrodojavnog sustava. Zbog toga je jako bitno da sustav posjeduje i rezervno napajanje (24V DC) koje se pri nestanku glavnog naizmjeničnog broorskog napona automatski uključuje s ciljem održavanja sustava i svih njegovih funkcija za vrijeme za koje se pretpostavlja da broorskog mrežnog napajanja neće biti određeno vrijeme, odnosno do ponovnog ukopčavanja broorskog mrežnog napona.

Rezervno napajanje vatrodojavnog sustava mora osigurati uz pouzdan rad i normalno funkcioniranje sustava u minimalnom vremenu određeno zahtjevom registara, odnosno o trajanju prekida broorskog glavnog mrežnog napajanja. Pod rezervnim napajanjem sustava misli se na akumulatorske baterije određenog kapaciteta koje su uvijek u stanju pripravnosti (*stand by*) te pri nestanku broorskog glavnog napajanja (220 VAC) omogućavaju daljnji nesmetani rad pomoću istosmjernog napona baterija (24 VDC).

Međunarodni standardi definiraju koje vrste baterija smiju biti u određenom broskom prostoru i kojeg minimalnog kapaciteta da zadovolje standard za dobivanje certifikata ispravnosti sustava. Treba napomenuti da se baterije u sklopu broorskog vatrodojavnog sustava najčešće nalaze unutar uređaja, što je rezultiralo da moraju biti suhe akumulatorske baterije. Upotrebom suhih baterija postiže se veća snaga, veća sigurnost i pouzdanost, manja je potreba za održavanjem, čime su se i smanjili troškovi. Kutija suhe baterije otporna je na vatru, vibracije i udarce te je hermetički zatvorena.

### 2.5.2. Raspoloživost broorskoga vatrodojavnog sustava

Pod raspoloživošću (engl. *availability*)  $A(t)$  broorskog vatrodojavnog sustava podrazumijeva se sposobnost za obavljanje zahtijevane funkcije, iskazane u odnosu na neko vrijeme ( $t$ ) ili u odnosu na određeno razdoblje tijekom djelovanja sistema vatrodojave.

Za izračun raspoloživosti  $A(t)$  koristi se izraz prikazan u obliku [24]

$$A(t) = \frac{\mu}{\lambda + \mu} + \frac{\lambda}{\lambda + \mu} e^{-(\lambda + \mu)t} = A_s + A_{tr}(t) \quad (2.9)$$

ili:

$$A(t) = \frac{\mu}{\lambda + \mu},$$

gdje su:

$$\begin{aligned} \mu &= \text{intenzitet popravka} & \mu &= \frac{1}{MTTR} \\ \lambda &= \text{indeks kvarova} & \lambda &= \frac{1}{MTBF}. \end{aligned}$$

Prema tome raspoloživost  $A(t)$  vatrodojavnog sustava može se odrediti prema izrazu:

$$A(t) = \frac{MTBF}{MTBF + MTTR} \quad (2.10)$$

gdje su:

$MTBF$  = srednje vrijeme između kvarova

$MTTR$  = srednje vrijeme popravka, odnosno do obnove komponenata

U pravilu na brodu u rezervi se mora nalaziti barem po jedan primjerak modula centralnog uređaja vatrodojavnog sustava. Također u rezervi mora biti određeni broj svakog tipa detektora.

$MTTR$  na brodu ovisi o trima faktorima:

- vrsti greške
- količini rezervnih dijelova i
- obučenosti posade pravilnim rukovanjem brodskim vatrodojavnim sustavom.

Uspješnost alarmnog vatrodojavnog sustava i alarmiranje zahtijeva besprijeckorno funkcioniranje brojnih komponenata međusobno povezanih u sustavu vatrododave. Slika 30 objašnjava stablo kvarova detekcije i alarmiranja požara podijeljeno u šest podsustava i to:

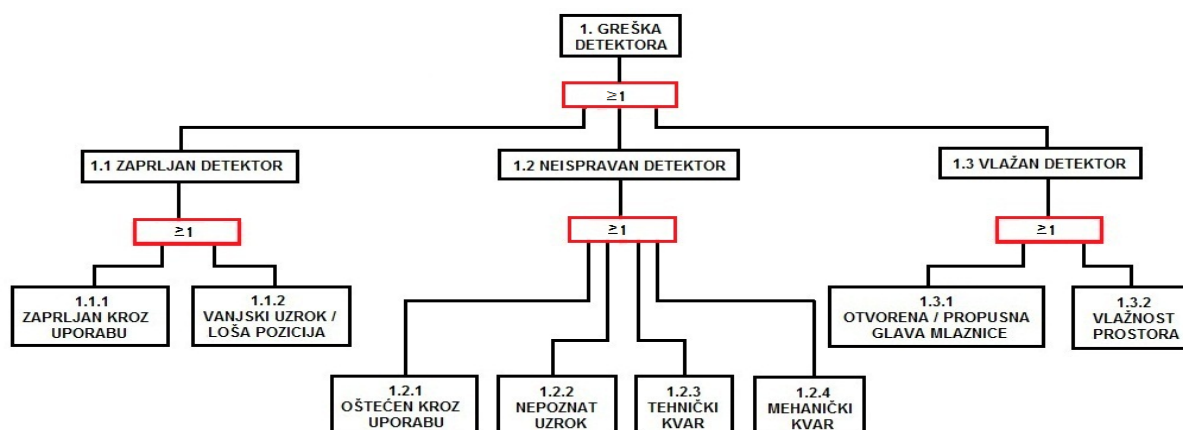
- stablo kvarova detektora
- stablo grešaka komponenata alarmnog požarnog sustava

- stablo grešaka signalna komunikacije podsustava
- stablo grešaka pomoćnih kontrolnih podsustava
- stablo grešaka napajanja
- stablo lažnih alarma.

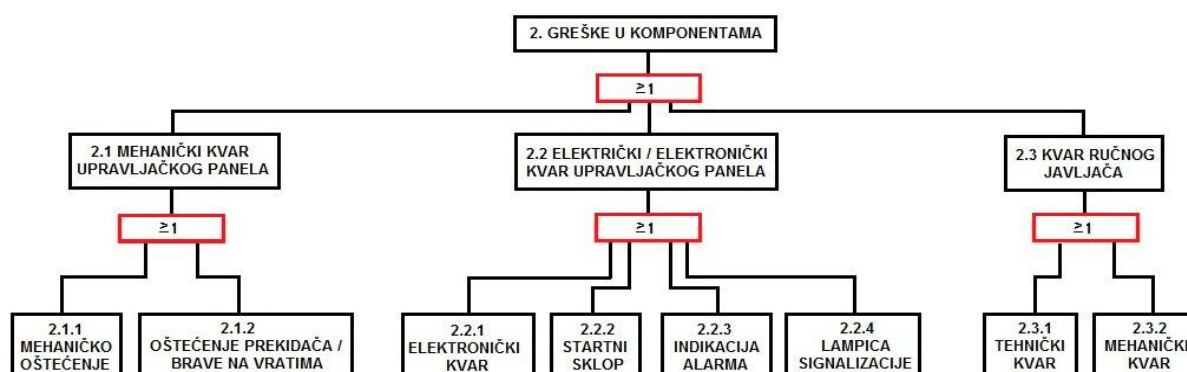


Slika 30: Stablo kvarovima detekcije i alarma požara podijeljen u šest podsustava

Svaki od šest podsustava dalje se mogu prikazati sa svojim stablom kvarova.

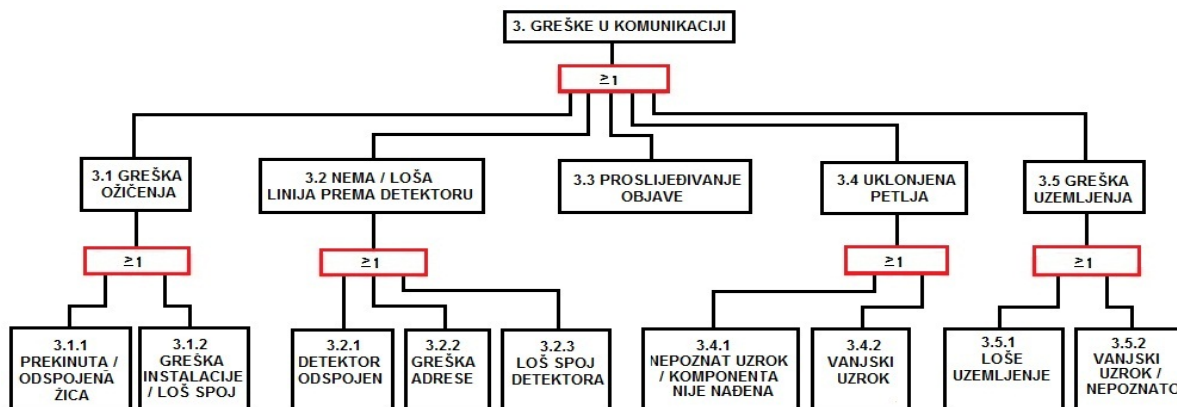


Slika 31: Stablo grešaka detektora

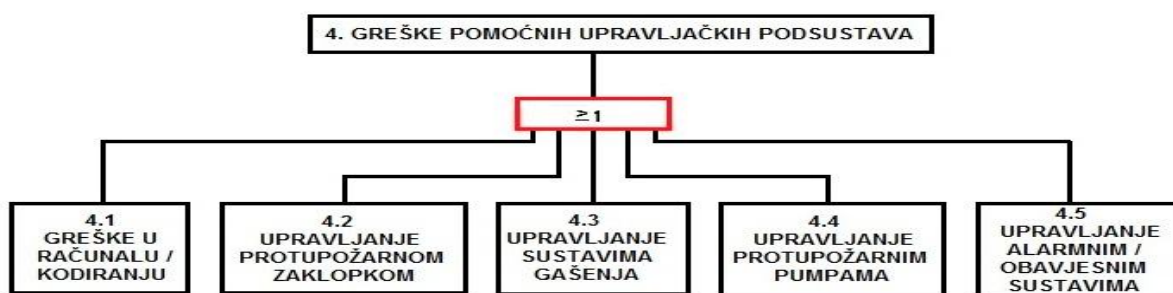


Slika 32: Stablo grešaka u komponentama





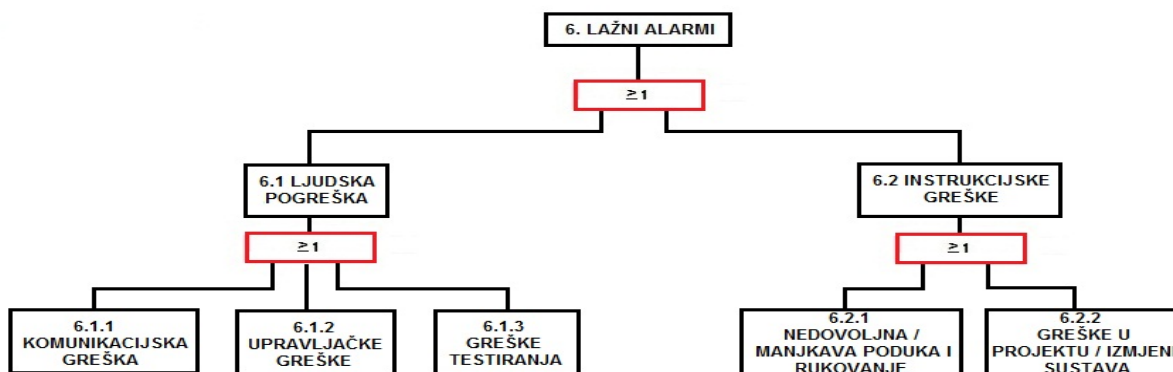
Slika 33: Stablo grešaka u komunikaciji



Slika 34: Stablo grešaka pomoćnih upravljačkih podsustava



Slika 35: Stablo grešaka napajanja



Slika 36: Stablo lažnih alarma

Kada znamo da je  $\lambda$  indeks kvarova,  $X$  broj kvarova,  $T$  vremenski interval tada procjenu stope greške vatrodojavnog sustava možemo prikazati kao [25]:

$$\lambda = \frac{X}{T}, \quad (2.11)$$

Raspoloživost svakog sustava pa tako i sustava vatrodojave je vjerojatnost da sustav radi bez zastoja obavljajući funkcionalno zadatke svakog trena. Osnovni čimbenici od kojih se sastoji raspoloživost su: svojstva samog sustava, okoline u kojoj djeluje i kvaliteta održavanja. U literaturi se opisuju više vrsta gotovosti kao što su vlastita, dostižna i operativna raspoloživost.

Vlastita raspoloživost je pokazatelj spremnosti samog sustava, a govori o njegovoj pouzdanosti. Pretpostavka vlastite raspoloživosti je pravilan rad sustava do kvara ili prestanka rada, a popravljiva se kad su uvjeti idealni, odnosno kad se steknu uvjeti za popravak.

U dostižnoj raspoloživosti uključuje se i vrijeme zastoja, pored vremena popravka i vremena održavanja, a računa se pomoću jednadžbe [24]:

$$A_0 = \frac{MTBM}{MTBM + \bar{M}}, \quad (2.12)$$

gdje su:

$MTBM$  = srednje vrijeme između održavanja

$\bar{M}$  = srednje vrijeme aktivnog održavanja.

Srednje vrijeme između održavanja određeno je izrazom:

$$MTBM = \frac{1}{\lambda + f_p} \quad (2.13)$$

gdje su:

$f_p$  = frekvencija preventivnog održavanja.

Srednje vrijeme aktivnog održavanja računa se kao:

$$\bar{M} = \frac{\lambda \cdot MTTR + f_p \cdot MPT}{\lambda + f_p} \quad (2.14)$$

gdje je:

$MPT$  = srednje vrijeme preventivnog održavanja.

Kod operativne raspoloživosti u obzir se uzima cjelokupno vrijeme zastoja zbog potrebnog održavanja. Ona prikazuje raspoloživost sustava u stvarnoj radnoj sredini i izražava se kao:

$$A_0 = \frac{MTBM}{MTBM + MDT} , \quad (2.15)$$

gdje su:

$MDT$  = srednje ukupno vrijeme zastoja radi održavanja sustava

$MTBM$  = srednje vrijeme između održavanja.

Praksa je da se srednje vrijeme zastoja održavanja prikaže i računa prema izrazu:

$$MDT = M + T_c + TL + TA \quad (2.16)$$

gdje su:

$T_c$  = srednje vrijeme čekanja početka održavanja

$TL$  = srednje logističko vrijeme čekanja na resurse održavanja

$TA$  = srednje administrativno vrijeme zastoja zbog administrativnih razloga.

Za izračun ukupnog vremena zastoja zbog održavanja sustava potrebno je u obzir uzeti sveukupno vrijeme, od zapažanja neispravnosti ili prestanka rada sustava radi preventivnog održavanja pa do vraćanja sustava u rad.

---

### 3. UZROCI NASTANKA I KARAKTERISTIKE POŽARA U BRODSKOJ STROJARNICI

Brodska strojarnica kao dio broda najviše je izložena vatri, s relativno malim brojem žrtava, uspoređujući broj mogućih žrtava u prostoru brodskih nastambi. Realno je očekivati da se vatra iz brodske strojarnice može vrlo lako proširiti u ostale dijelova broda. Zbog toga je zaštita od požara u brodskoj strojarnici temelj cjelokupne sigurnosti u prvom redu posade i putnika, a potom broda i zaštita okoliša, regulirano međunarodnim pomorskim zakonima.

SOLAS konvencija i IAKS (Internacionalna udruga klasifikacijskih društava) usvojili su pravila i zahtjeve za novogradnje u vezi sigurnosti prostora brodskeg motora, odnosno brodske strojarnice, od požara. Ta pravila su [26]:


- ako je protok fluida previsok, promjer cijevi povratka mora biti 25 % veća od glavne cijevi
- sve cijevi kroz koje prolazi ulje na temperaturama višim od 60 °C moraju biti vidljive
- senzori montirani na cijevi protoka fluida moraju biti spojen na glavnu cijev preko ventile
- kontrola nepropusnosti drenažnih cijevi s mogućnosti pražnjenja drenaže u posebne spremnika, a ne dozvoliti prelijevanje sustava;
- osim regulacije temperature, grijači pare za gorivo ili ulje za podmazivanje moraju biti opremljeni alarmima za visoke i niske temperature;
- kako bi se spriječilo površinsku temperaturu da prelazi 20 °C, električni grijači moraju biti stalno uronjeni u kontrolirani medij.

Uvjeti potrebni za izbijanje vatre u brodskoj strojarnici ne mogu se izbjeći. Kisik je potreban za normalno funkcioniranje života posade, ali i pravilan rad glavnog stroja. Uz to stalno su prisutne visoke temperature uslijed rada sustava brodske strojarnice, kako bi strojarnica pravilno funkcionirala. Bezbroj električnih sustava uvijek su potencijalni uzrok mogućeg požara. Zbog toga najbolja odbrana od požara je zaustavljanje u samom začetku, ili da se spriječi njegov nastanak pravilnim održavanjem svih brodskih sustava.

### 3.1. Utjecajni čimbenici za razvitak požara u broškoj strojarnici

Požari u broškoj strojarnici rezultat su kombinacije triju čimbenika, slika 37 i to:

1. zapaljiva tvar
2. dovod zraka
3. izvor paljenja.



Slika 37: Osnovni uvjeti gorenja


Ova tri faktora predstavljaju strane trokuta požara. Uklanjanjem jednog, bilo kojeg čimbenika trokuta rezultirat će sprječavanjem požara, odnosno njegovim gašenjem. Potpuna odsutnost bilo kojeg od triju čimbenika osigurati će izostanak vatre.

Prva strana trokuta su zapaljive tvari koje se mogu spaljivati u izobilju kao što su spremnici nafte, cijevi pune ulja, nauljene krpe itd. Ovi uzroci mogu se ukloniti dobrim gospodarenjem u strojarnici, učinkovito upravljanjem smećem, dobrim održavanjem cjevovoda, prirubnica, brtvi, strojeva.

Uzrok druge strane trokuta – dovod zraka (kisika), odnosno golema količina zraka u strojarnici, a služi za rad turbopuhala glavnog motora, turbina pomoćnih motora, odnosno za izgaranje goriva u glavnom i pomoćnim motorima, zatim hlađenje strojarnice ventilacijom te rad kotlova i spalionice otpada.

Uzrok treće strane trokuta – izvor paljenja, može biti prisutan ponekad zbog kvara materijala ili izolacije, ali i zbog ljudske pogreške. Nepravilno održavanje strojeva i uređaja u strojarnici mogu biti uzrokom kasnijih požarnih incidenata. Loše održavan glavni motor također može biti uzrokom paljenja kao što je eksplozija kartera koja može biti uzrokom požara cijele strojarnice.

Prema statističkim podacima svjetske flote požari nastali u brodskoj strojarnici čine 63 % ukupnih brodskih požara, iz čega proizlazi da je područje brodske strojarnice posebno vatri, vidljivo iz grafikona 1.



Grafikon 1: Prikaz podrijetla i uzroka požara na brodovima

U njoj se nalaze različite vrste sustava i uređaja međusobno povezani rizicima. Sama strojarnica sadrži brojne tankove, kao što je zagrijani tank teškog goriva, tank ulja za podmazivanje, cilindričnog ulja, hidrauličnog ulja, tank dizelskog goriva, različite masti i kemikalije. Prosječno veliki brodovi troše od 20 do 40 tona loživog goriva na dan. Da bi glavni motor mogao funkcionirati, gorivo mora biti ugrijano u rasponu od 120 do 150 °C s tlakom na visokotlačnim pumpama do 1200 bara. Uređaj poput parnog kotla koji se koristi za proizvodnju pare za grijanje teškog goriva kao pogonskog goriva glavnog motora, da bi mogao funkcionirati i sam koristi gorivo. Spalionica brodskog otpada kao što su masne krpe, mulj i drugi operativni otpad spaljuju se na temperaturi od 850 °C i više. Navedeni sistemi sa svojim uređajima i cjevovodima potencijalno su mogući izvor požara, ukoliko nisu pravilno održavani ili su neispravni.


Na svojoj 86. sjednici 2009. godine, IMO – Odbor za pomorsku sigurnost usvojio je dokument pod nazivom “Preporuka za prevenciju zaštite brodske strojarnice i pumpnih stanica od požara [27]“. Konačni nacrt zahtjeva za prevenciju zaštite, tj. sprječavanja od požara, rezultat je koordiniranog timskog rada IMO odbora za sigurnost od požara i rada radnih skupina s odabranim članovima iz istraživačkih instituta, skupine brodograditelja, klasifikacijskih društava i IMO predstavnika država članica – Argentina, Kina, Danska, Francuska, Iran, Japan, Koreja, Norveška, Velika Britanija, SAD, i Poljska. Regulatorni

propisi nastali su na temelju statističkih podataka provedenih tijekom praćenja 6000 plovila u periodu od 13 godina. Utvrđeno je da je 73 požara na trgovačkim brodovima prouzročeno u brodskoj strojarnici. Učestalost požara u strojarnicama tijekom razdoblja obuhvaćenog istraživanjem je 1 požar godišnje na 1013 plovila, što je ukupno 6 požara godišnje. Oko 75 % požara u brodskoj strojarnici događao se na brodovima u pokretu. Za većina požara neizravno je krivac 'ljudski faktor'.

### 3.1.1. Uzroci požara u strojarnicama

Uzroci požara u strojarnici dobiveni teorijskom analizom prikazani su na grafikonu 2 [28]:

- 1 – sustavi za gorivo 40 %
- 2 – maziva ulja sustavi 30 %
- 3 – električna sustavi 10 %
- 4 – turbo-kompresori i cijevi ispušnih plinova 3 %
- 5 – sustav uljnih otpada (postrojenja za spaljivanje) 5 %
- 6 – ostalo 12 %.



Grafikon 2: Uzroci požara u brodskim strojarnicama

Izvor: *Journal of KONES Powertrain and Transport*, Vol. 18, No. 2 2011.

Jedan od najbrojnijih uzroka brodskih požara su kvarovi na električnim instalacijama naizmjenične ili istosmjerne struje. Kad se govori o istosmjernoj struji prvenstveno se misli na početak požara uzrokovan kabelima akumulatora/baterija, dok kod naizmjenične struje na kabelima i žicama raznih brodskih uputnika, pumpi, kompresora i ostalih uređaja, a često i na žicama instrumenata uslijed oštećenja izolacije jakim vibracijama prouzročenih radom

pogona strojarnice. Požari na električnim instalacijama su teško gasivi, vatra se može ponovo vrlo lako vratiti i nakon intervencije sustavima za gašenje požara ili ručnim protupožarnim aparatima. Posebna pažnja poklanja se manje opasnim požarima nastalima pregrijavanjem propulzivnog sistema koje se može desiti uslijed začepljenja sistema rashlade, sistema podmazivanja ili kvara na pumpama, zbog količine dima uzrokovanim takvim požarima, iz razloga jer dim dolazi iz prostora smještaja raznih sustava i njima pripadajućih spremnika, odnosno tankova goriva, ulja i ostalih tekućih fluida.

### 3.1.2. Čimbenici požara u strojarnici

Općenito, nastanak požara i njegovo širenje u brodskoj strojarnici, ovisi o raznim čimbenicima [29]:

- vrsti goriva i ukupnoj količini
- smještaju gorivog materijala
- količini protoka zraka
- izgledu gorivog materijala
- brzini gorenja materijala
- uzroku nastalog požara (električne instalacije, iskre, varenje, odbačeni opušak cigarete, namjerna paljevina, eksplozija)
- izoliranosti vrućih površina i vrućih cjevovoda
- instaliranim uređajima za gašenje požara
- pravilnim rukovanjem protupožarnim sustavima.

Sljedeća tablica (7) prikazuje rezultate provedene istraživanjem, sažete izračunima relativnog požara za teško i dizelsko gorivo, dok tablica 8 frekvenciju učestalosti požara uređaja u brodskoj strojarnici.

Tablica 7: Frekvencija učestalosti požara izazvana teškim i dizelskim gorivom

Sistem	Učestalost	
	Broj požara	Broj brodova godišnje
	[1/brod godina]	[1/požar]
Loživo ulje	$4.04 \times 10^{-4}$	2474
Dizelsko gorivo	$1.67 \times 10^{-4}$	6000
Ukupno	$5.71 \times 10^{-4}$	1751

Izvor: *Journal of KONES Powertrain and Transport*, Vol. 18, No. 2 2011.



Tablica 8: Frekvencija učestalosti požara uređaja u brodskoj strojarnici.

Sustavi	Učestalost požara [1/brod godina]	Udio u općoj učestalosti
	$1.73 \times 10^{-4}$	0.3001
Glavni motor (ulje za podmazivanje)	$8.58 \times 10^{-5}$	0.1492
Generatori (loživo ulje)	$2.25 \times 10^{-4}$	0.3923
Generatori (ulje za podmazivanje)	$7.84 \times 10^{-5}$	0.1363
Kotao	$1.04 \times 10^{-5}$	0.0181
Ulje za spaljivanje otpada	$3.79 \times 10^{-7}$	0.0006
Spremnici goriva	$1.82 \times 10^{-7}$	0.0003
Ostali sustavi i cjevovodi	$1.72 \times 10^{-6}$	0.0031
Ukupno	$5.75 \times 10^{-4}$	1.0000

Izvor: *Journal of KONES Powertrain and Transport*, Vol. 18, No. 2 2011.

Kada govorimo o izvoru paljenja postoje dva scenarija. Prvi scenarij uzrokuje brodski uređaji kao stalni izvori paljenja, čije toplinsko zračenje može stvoriti temperaturu paljenja zapaljivih materijala (ispušne cijevi glavnog motora i pomoćnih motora, ispušne cijevi kotla i spalioća otpada, jedinica za pripremu goriva). Drugi scenarij paljenja su sustavi i uređaji koji u redovnom i uobičajenim uvjetima nisu potencijalni izvori paljenja kao npr. elektroventilatori, kompresori, separatori i dr.

Zapaljivost ovisi o [30]:

- tipu i izgledu površine
- veličini zapaljive površine
- temperaturi određenog predmeta ili okoline
- koncentraciji zapaljive smjese.

Kada je vrijeme zadržavanja gorive smjese na zagrijanoj površini dugo, može doći do reakcija pri kojoj mogu nastati lakozapaljivi produkti kao potencijalni izvor požara. Površine zagrijane bez vanjskog utjecaja, kao što su recimo, zagrijavanje pokretnih dijelova nepravilnim održavanjem (nepodmazivanjem, nečišćenjem od čestica prašine, masti, ulja i slično) mnogo su opasnije.


### 3.1.3. Izvori paljenja

Izvori kao i uzroci požara imaju najveći značaj u njegovom nastajanju. Izvori paljenja podijeljeni su na tri osnovne grupe. Sama podjela izvora paljenja napravljena je na osnovi udaljenosti izvora paljenja od požarnog mjesta. Prema tom kriteriju slijedi da [31][32] [33]:

- ukoliko se paljenje požarnog prostora vrši iz izvora udaljenog od požarnog mjesta ili je požarni prostor pregradom odvojen od izvora paljenja tada je to vanjski izvori paljenja
- ukoliko je paljenje inicirano iz požarnog prostora, odnosno požarni prostor posjeduje vlastiti izvor paljenja, tada je to unutarnji izvor paljenja
- treću grupu izvora čine paljenja gdje se izvori paljenja nalaze djelomično u prostoru zahvaćeno požarom, te se još nazivaju parcijalni izvori paljenja.

Kao izvori zapaljenja, prikazani na slici 43 navedeni su:

- zagrijane površine
- plamen
- kemijski izvor
- iskre mehaničkog podrijetla
- iskre električnog podrijetla.



Slika 38: Izvori paljenja

Toplinska energija potrebna za početak paljenja može se svrstati u četiri osnovne kategorije:

- toplinska energija koja nastaje kemijskom reakcijom (toplinska oksidacija, toplina izgaranja, spontano grijanje, toplina uslijed razgradnje itd.)
- električna toplinska energija (indukcijsko grijanje, toplina tijekom iskrenja udar groma, elektrostatički naboj, električne iskre itd.)
- mehanička toplinska energija kao što je toplina trenja
- toplinska energija uslijed nuklearnog raspadanja.

### 3.1.3.1. Zagrijane površine

Paljenje zahtijeva povoljne početne uvjete, a to su u pravilu dovoljno zagrijani sustavi ili površine koje pokrivaju početnu energetska potrebu za početno iniciranje paljenja. U praksi, sva kruta tijela kao površine raznih brodskih oprema i uređaja mogu se zagrijati do opasne temperaturne granice bilo redovnim radom ili zbog kvara. Površine tako mogu biti zagrijane na dva načina, indirektno (kotao, ispušne cijevi glavnog stroja i pomoćnih motora, cijevi pare itd.) i indirektno, odnosno nenamjerno uslijed trenja ili nedovoljnog hlađenja zagrijanih površina. Zagrijane površine mogu zapaliti zapaljive materijale koji su u njihovoj blizini, ali i materijale koji dolaze u direktan kontakt sa zagrijanom površinom.

Lars-Goran Bengtsson u svojoj knjizi "Enclosure fires" je obrazložio da se površinska temperatura krutog materijala  $T_s$  može izračunati pomoću jednadžbe poznate kao opća toplinska vodljivost, a glasi [32]:

$$T_s - T_i = \frac{2q'' t^{0,5}}{\pi^{0,5} (kpc)^{0,5}}, \quad (3.1)$$

gdje su:

$q''$  = toplina W / m<sup>2</sup> - zračenja energije (u ovom slučaju, požar)

$T_s$  = površinska temperatura (°C) za kruto gorivo

$T_i$  = početna temperatura (°C) od površine goriva (izvorni temperatura)

$k$  = toplinska vodljivost W / m<sup>2</sup> °C (visoki koeficijent znači da dobru toplinsku vodljivost materija)

$p$  = gustoća u kg / m<sup>3</sup>

-----

$c$  = Specifični toplinski kapacitet u J/kg °C (to znači sposobnost materijala je da pohrani toplinu)

$t$  = Vrijeme u sekundama (sek.).

### 3.1.3.2. Otvoreni plamen

Otvoreni plamen je najjednostavniji i najčešći izvor paljenja. Velik broj alata u općoj upotrebi i razne vrste tehnološke opreme rade s otvorenim plamenom, ili omogućuju stvaranje otvorenog plamena. Plamenici, šibice, peći, oprema za grijanje, plamen plamenika za zavarivanje, slomljena ili oštećene plinske cijevi, cijevi nafte, itd., mogu se smatrati potencijalnim izvorima paljenja, jer s otvorenim plamenom kao primarnim izvorom paljenja predstavljaju mehanizam za paljenje odnosno širenje gorenja na druge sustave, pod uvjetom da izvor paljenja s otvorenim plamenom posjeduje dovoljnu količinu energije za pokretanje paljenja.

### 3.1.3.3. Kemijski izvori

Kemijske reakcije kao unutarnji izvori paljenja generiraju toplinu dovoljnu za početak paljenja. Materijali skloni spontanom grijanju i spontanom zapaljenju mogu postati sekundarni izvori paljenja i dovesti do zapaljenja ostalih zapaljivih materijala u blizini.

Iako su neki plinovi i tekućine kao kemijski izvori skloni spontanom zapaljenju, većina spontanih paljenje pojavljuju se kao površinske reakcije čvrstih materijala. Spontano zapaljenje ovisi o kemijskoj strukturi materijala. Velika specifična površina omogućuje lokalno nakupljanje reakcijske topline i doprinosi povećanju temperature materijala iznad spontane temperature paljenja. Važno je napomenuti da spontana grijanja u nekim slučajevima mogu biti zbog pogrešnih tehnoloških uvjeta kao što su nedovoljna ventilacija, nizak kapacitet hlađenja, nepodudarnosti održavanja i čišćenja, pregrijavanja.

### 3.1.3.4. Iskre mehaničkog podrijetla

Tehnička praksa uvijek je povezana s trenjem. Uslijed mehaničkog rada, razvija se toplina trenja, ali ako je gubitak topline ograničen u tolikoj mjeri da se toplina akumulira u samom sustavu, njegova temperatura se može povećati na vrijednost koja je opasna za okolinu, uslijed čega može doći do požara .

Iskre uslijed trenja obično se javljaju tijekom tehnoloških operacija raznih metala, prilikom brušenja, struganja, rezanja ili udaranja, ali i zbog pada određenog predmeta na tvrdu podlogu. Temperatura mehaničke iskre obično je viša od temperature paljenja od konvencionalnih zapaljivih materijala kao što su iskre iz čelika, 1.400 – 1.500 °C; iskre iz bakrene legure nikla, 300 – 400 °C. Međutim, sposobnost paljenja ovisi o sadržaju količine topline i najniže energije paljenja materijala i tvari koja se zapali. Praksa je potvrdila da iskre nastale mehaničkim trenjem predstavljaju srednji rizik za požar u zračnim prostorima u kojima se nalazi opasna koncentracija zapaljivih plinova, para i prašina.

### **3.1.3.5. Iskre električnog podrijetla**

Strojevi, instrumenti i uređaja kojima se upravlja pomoću električne energije, kao i oprema za transformaciju električne energije i rasvjete, obično ne predstavljaju nikakvu opasnost od požara u svom okruženju, pod uvjetom da su instalirani u skladu s odgovarajućim propisima sigurnosti i zahtjevima standarda. Redovito održavanje i periodični nadzor znatno smanjuju vjerojatnost mogućih požara i eksplozija koji bi mogli biti inicirane iskrom električnog podrijetla. Najčešći uzroci požara u električnim uređajima i instalacijama su razna preopterećenja, kratki spojevi ili visoki kontaktni otpori.

Električne iskre kao toplinski mali izvori energije prirode, često djeluju kao izvor paljenja. U standardnim uvjetima rada, većina električnih uređaja ne oslobađa iskre, međutim rad pojedinih uređaja obično je popraćen iskrama.

Iskrenje je opasnost prvenstveno na mjestima gdje mogu nastati eksplozivne koncentracije plina, pare, prašine ili mjesta propuštanja goriva ulja i naslaga masnoća. Prema tome, iskrenje tijekom rada dopušteno je samo na mjestima gdje iskre ne mogu dovesti do iniciranja požara. Razvoj požara ili rizik od eksplozije zahtijeva prisutnosti bilo kakvog zapaljivog medija i pražnjenja energije (iskra) sa sposobnošću za paljenje. Ova opasnost uglavnom se javlja na temelju iskre kao minimalne energije paljenja za osjetljivo opasne materijale, a ovisi o stupnju energetskog punjenja.


Udar groma odnosno munja je električna prirodna pojava koja se također smatra izvorom paljenja. Statičko punjenje nastalo u oblacima teži pražnjenju visoke energije prema zemlji kao udar groma. Gorive tvari na mjestu udara munje i u bližoj okolini mogu se zapaliti i izgorjeti. Zbog toga jako je bitna i zaštita broda od udara groma, da ne bi došlo do nesagledivih posljedica.

### 3.2. Faze razvoja i prijenos požara

Požar može izbiti i razviti se na mnogo različitih načina. Na razvoj požara u najvećoj mjeri utječe količina zapaljivih materijala i njihov raspored u brodskoj strojarnici. Opskrba zrakom (kisikom) jedan je od ključnih faktora. Postepenim smanjenjem prisutnosti kisika doći će i do smanjenja intenziteta požara, što će doprinijeti smanjenju temperatura dimnih plinova u prostoru strojarnice. Gubitkom gorivog materijala postiže se brži gubitak topline. Razvoj požara u zatvorenom prostoru (brodska strojarnica) i njena temperaturna krivulja koja opisuje taj razvoj ovisi o nizu faktora kao npr.: geometrija prostora, ventilacija prostora i toplinske osobine prostorno ugrađenih materijala.

#### 3.2.1. Faze razvoja požara

Idealna temperaturna krivulja razvoja požara u zatvorenoj prostoriji, pa tako i brodskoj strojarnici, ima četiri različite faze: početnu fazu odnosno fazu nastajanja požara, razvojnu fazu od paljenja do preskoka (*flashover*<sup>1</sup>), fazu ili period potpuno razvijenog požara i fazu gašenja, tj. razdoblje slabljenja požara. Krivulje rasta požara obično su prikazane kao na slici 44, a ona predstavlja opis intenziteta (brzina oslobađanja topline) požara u funkciji vremena.



Slika 39: Krivulja različitih ponašanja požara

1 Pojam *flashover* definira se kao moment prelaska iz rane faze razvoja požara u fazu potpuno razvijenog požara. To je trenutak kada dolazi do paljenja cjelokupnog materijala koji je bio pod utjecajem toplotnog zračenja i često je praćen bljeskom.

Također, imamo slučajeve kada je prijelaz rane faze razvoja požara u potpuno razvijen požar moguć bez preskoka, uz uvjet da brzina oslobađanja topline nije dovoljno velika uslijed manjka goriva, ventilacije ili ostalih uvjeta potrebnih za širenje požara. Ukoliko je jačina i period trajanja potpuno razvijenog požara znatno manji (bez preskoka) tada je i krivulja znatno drugačija (donja krivulja na slici).

U nedostatku kisika, odnosno kada je razina kisika u strukturi potrošena, vatra se smanjuje, oslobađanje topline uzrokovano požarom se smanjuje i kao rezultat toga se smanjuje i temperatura okoline. Uvijek postoji opasnost uslijed ponovnog dovođenja svježeg kisika te miješanjem s grijanim plinovima okoline jer razina energije počinje rasti. Ova promjena koju može prouzročiti i ventilacija dovodi do naglog povećanja rasta požara te potencijalno dovodi do stanja površinskog pražnjenja.

### 3.2.1.1. Faza nastajanja požara

Faza nastajanja požara može se podijeliti u dva dijela i to na stupanj paljenje i stupanj tinjanja. Paljenja nastaje kada su ispunjeni potrebni uvjeti gorenja prikazani trokutom (Slika 42) na početku poglavlja. Tinjanje (oksidacija krutih stvari) nastaje uslijed nedovoljne količine kisika uvjetovane dotokom svježeg zraka ili uslijed ventilacije prostora. Problem tinjanja je što je često nevidljiv, međutim detektira se osjetilom njuha. Količina dima nastala tinjanjem može se razviti do takvih razmjera da dim ispuni i prostoriju poput brodske strojarnice.

Paljenje se nadalje može podijeliti u dvije kategorije. Prva ima inicijalno paljenje koje prouzrokuje iskra ili plamen koji inicira vatru. Druga kategorija događa se spontano gdje plamen nastaje kao rezultat zagrijavanja određenog materijala. Osim plinova i tekućeg medija svi ostali materijali prije paljenja prvo moraju biti zagrijani. Vrijeme paljenja po Larsu-Goranu Bengtssonu može se izračunati pomoću jednadžbe 3.2, što je preoblikovanje jednadžbe 3.1. Treba napomenuti da je izostavljena površinska otpornost na toplinu i da se temperatura paljenja koje je on obrađivao najčešće kreće u rasponu od 300 °C do 400 °C.

Kada je temperatura paljenja  $T_{sa}$  poznata vrijeme paljenja  $t_a$  može se izračunati jednadžbom [32] [34] [35]:

$$t_a = \frac{(T_{sa} - T_t)^2}{4(q'')^2} k\rho c x \pi, \quad (3.2)$$

gdje su:

$t_a$  = vrijeme paljenja (sek.)

$T_{sa}$  = temperatura paljenja (°C)

$q''$  = toplina W/m<sup>2</sup> - zračenja energije (u ovom slučaju, požar)

$T_i$  = početna temperatura (°C) od površine goriva (izvorni temperatura)

$k$  = toplinska vodljivost W/m<sup>2</sup> °C (visoki koeficijent označava dobru toplinsku vodljivost materijala)

$p$  = gustoća u kg/m<sup>3</sup>

$c$  = specifični toplinski kapacitet u J/kg °C (sposobnost materijala za pohranu topline).

U publikaciji objavljenoj od strane društva inženjera SFPE (Society of Fire Protection Engineers) prikazano je šest metoda predviđanja paljenja čvrstih materijala. Za tanke materijale poput lima metoda izračuna paljenja koju su prezentirali Mikkola i Wichman prikazana je jednadžbom [36] [39]:

$$t_{ig} = \rho L_0 c \frac{(T_{ig} - T_0)}{(q''_r - q''_{krit})} , \quad (3.3)$$

gdje su:

$t_{ig}$  = vrijeme potrebno za paljenje (sek.)

$T_{ig}$  = temperatura zapaljenja (°C)

$T_0$  = početna temperatura (°C)

$p$  = gustoća materijala (kg/m<sup>3</sup>)

$c$  = specifična toplina materijala (kJ/kg·C)

$L_0$  = debljina materijala (m)

$q''_r$  = vanjski tok topline (kW/m<sup>2</sup>)

$q'''_{krit}$  = kritična temperatura toplinskog toka potrebnog za paljenje (kW/m<sup>2</sup>)



Za deblje materijale prezentirane metode izračuna paljenja glase [36] [37] [38] [41]:

- Mikkola i Wichman:

$$t_{ig} = \frac{\pi}{4} kpc \frac{(T_{ig}-T_o)^2}{(q_r-q_{krit})^2} , \quad (3.4)$$

gdje je:

$k$  = toplinska vodljivost (W/m·K)

- Tewarson:

$$t_{ig} = \frac{\pi}{4} \frac{(TRP)^2}{(q_r-q_{krit})^2} , \quad (3.5)$$

gdje su:

$TRP$  = povratni toplinski parametar (kW·sec<sup>1/2</sup>/m<sup>2</sup>)

$q''_{min}$  = minimalni temperatura toplinskog toka potrebnog za paljenje (kW/m<sup>2</sup>)

- Quintiere i Harkleroad:

$$t_{ig} = \left( \frac{\dot{g}_{min}''}{b \dot{g}_r''} \right)^2 \text{ for } t \leq t_m , \quad (3.6)$$

gdje su:

$b$  = konstanta povezana s kpc (sek<sup>-1/2</sup>)

$t_m$  = vrijeme do toplinske ravnoteže (sek)

- Janssens:

$$t_{ig} = 0.536 \left( \frac{kpc}{h_{ig}^2} \right) \left( \frac{\dot{g}_r''}{\dot{g}_{krit}''} - 1 \right)^{-1,83} \quad (3.7)$$

gdje je:

$h_{ig}$  = koeficijent prijenosa topline kod paljenja (W/m<sup>2</sup>·C)

- Toal, Silcock i Shields

$$t_{ig} = \frac{(FTP_n)}{(q_r'' - q_{crit}'')^n}, \quad (3.8)$$

gdje su:

$FTP_n$  = vremenski tok produkta

$n$  = indeks vremenskog protoka produkta koji je veći ili jednak 1.

Da bi došlo do paljenja tekućih fluida temperatura paljenja mora biti jednaka ili veća od temperature zapaljivosti. Nacionalna udruga za zaštitu od požara NFPA (National Fire Protection Association) sa sjedištem u Quincy, Massachusetts, USA, pod kodom 30 daje definiciju plamišta za zapaljive tekućine, a glasi "minimalna temperatura tekućine u kojoj ima dovoljno para koje formiraju zapaljivu smjesu sa zrakom blizu površine tekućine zove se plamište." [40] ili jednostavnije, plamište je najniža temperatura tekućine pri kojoj njezine pare tvore zapaljivu mješavinu sa zrakom. Niz metoda ispitivanja mogu se upotrijebiti za mjerenje plamišta tekućina.

Točka samozapaljenja (engl. *Flashpoint*) kod tekućih fluida je pojava povezana s isparavanjem dovoljne količine goriva za uspostavu plinske mješavine iznad površine goriva koja se može upaliti vanjskim izvorom topline.

Tablica 9: Plamišta i temperature samozapaljenja s obzirom na vrstu zapaljive tekućine

Zapaljiva tekućina	Plamište °C	Temperatura samozapaljenja
Dizelsko gorivo	40	430 do 480
Etilni alkohol	12	425
Benzen	-17	530
Benzin	-20 do -40	530
Dietileter	-45	170

U svome radu Le Chatelier's u publikaciji objavljenoj od strane društva inženjera SFPE definira načelo po kojem se određuju donji limiti zapaljivosti tekućina, a glasi [41] [42]:

$$L_m = \frac{100}{\sum_i \frac{p_i}{L_i}} \quad (3.9)$$

gdje su:

$L_m$  = donja granica zapaljivosti smjese

$P_i$  = volumen plina

$L_i$  = donja granica zapaljivosti plina.

### 3.2.1.2. Rana faza razvoja požara

Kad govorimo o ranoj fazi razvoja požara, brzina razvoja ovisi o karakteristikama zapaljivih materijala kao što su kemijska ili fizička svojstva. Rana faza požara nastaje u trenutku paljenja gorivog materijala. Osnovni parametri početnog požara su: sadržaj kisika u zraku zatvorenog prostora je najmanje 17 % volumena, temperatura u unutrašnjosti npr., brodske strojarnice nije veća od 60 °C, a visina dimne zavjese u opožarenom prostoru (dvodno strojarnice) je do 1,5 m mjereno od poda. U ovoj ranoj fazi požar ima indiciju brzog širenja do razine nekontroliranog stanja (tzv. *Flashover*). Ekspanzija požara u zahvaćenom prostoru odvija se na način da se vertikalno širenje požara dešava brže od horizontalnog širenja. Razlog tome je prijenos topline konvencijom čime se gorivi materijal pregrijava, ubrzavajući njegovo sagorijevanje.

Karakteristike rane faze razvoja požara su [43]:

- dodatno gorivo pospješuje vatru
- veličina požara se povećava
- oblak vrućih plinova i plamena stvaraju struju koja nosi vruće plinove do stropa prostorije zahvaćene požarom
- plamen se počinje širiti prema gore i prema vanjskim izlazima iz prostorije zahvaćene požarom
- zračenje počinje igrati veću ulogu u rastu vatre
- temperatura u prostoru zahvaćenom požarom povećava se kako vatra raste
- dovoljna količina kisika na raspolaganju
- ako plamen doprije do stropa vjerojatno je da će se proširiti po cijeloj prostoriji zahvaćenoj požarom.

-----

Inače dim i nastali plinovi koji se razvijaju na samom početku rane faze požara, osim što djeluju zagušujuće i otrovno, stvaraju dodatni problem za sam proces evakuacije prije svega posadi broda iz prostora strojarnice radi smanjene vidljivost. Slijedom toga može doći do situacija opasnih po život što se uslijed smanjene vidljivosti, naglog razvoja požara i rasta temperature, te velike količine dima dogodilo na dvjema novogradnjama brodogradilišta Uljanik.

### 3.2.1.3. Faza potpuno razvijenog požara

Faza potpuno razvijenog požara odlikuje se naglim porastom temperature uz brzo širenje požara, do razine stanja koje se ne može kontrolirati. Prisustvo gorivih materijala pospješuje te se u vrlo kratko vrijeme razvijaju temperature i preko 1100 °C pri kojoj ne gore samo prisutne zapaljive materije već i sam konstrukcijski materijal prostora zahvaćenog požarom.

Da bi se uopće razumio proces širenja požara i požarnog procesa mora se znati i kako se prenosi toplota (energija). Zato je potrebno skrenuti pozornost na tri mehanizma prijenosa topline i to: provođenjem, konvekcijom i zračenjem. Osnovne jednačbe za prijenos topline stabilnog stanja su [45] [46]:

Kondukcija:

$$\dot{q}'' = \frac{k}{l} (T_1 - T_2) \text{ kW/m}^2, \quad (3.10)$$

Konvekcija:

$$\dot{q}'' = h(T_1 - T_2) \text{ kW/m}^2, \quad (3.11)$$

Zračenje:

$$\dot{q}'' = \varepsilon \sigma (T_1^4 - T_2^4) \text{ kW/m}^2, \quad (3.12)$$

gdje su:

$k$  = svojstvo materijala poznato kao toplinska vodljivost (kW/mK)

$l$  = udaljenost (m) gdje temperatura padne od  $T_1$  do  $T_2$  (u stupnjevima

Kelvina)

$h$  = koeficijent konvektivnog prijenosa topline ( $\text{kW/m}^2\text{K}$ )

$\varepsilon$  = emisivost (učinkovitost površinskog zračenja)

$\sigma$  = Stefan - Boltzmaonva konstanta ( $56.7 \times 10^{-12} \text{ kW/m}^2\text{K}^4$ ).

Karakteristike potpuno razvijenog požara su [47]:

- temperatura se povećava do točke gdje zapaljive tvari u prostoriji prolaze pirolizu
- velike količine hlapljivih plinova
- *flashover* (uslijed toplinskog zračenja dolazi do paljenja sveukupnog materijala ) a javlja se
  - kada temperatura u prostoriji dosegne točku gdje se zapaljivi sadržaj u prostoru može zapaliti odjednom;
  - kada je požara u konačnom procesu rasta;
  - kada je kritična temperatura za površinskog pražnjenja oko  $1000^\circ\text{C}$
- kada gasitelji požara ne mogu preživjeti više od nekoliko sekundi tijekom površinskog pražnjenja
- količina požara ovisi o količini kisika na raspolaganju
- kada je ukupna šteta od požara u zahvaćenom prostoru rezultat intenziteta topline i vremena tijekom kojeg je taj prostor izložen toj toplini
- suzbijanje požara može utjecati na širenje požara
- pozitivan ventilacijski tlak može razviti požar u području i prostoru koja možda nisu zahvaćena požarom
- vatra slijedi put konvekcijske struje dima i pregrijava plinove.

#### 3.2.1.4. Razdoblje slabljenja požara


Obično je to najduža faza požara. Slabljenje požara je stadij koji karakterizira značajan pad kisika ili goriva, što doprinosi postepenom gašenju i potom kraju požara.

Dvije zajedničke opasnosti tijekom ove faze su:

- postojanje ne plamtećih zapaljivih ostataka, što potencijalno može izazvati novu vatru, ukoliko gorivi ostaci nisu u potpunosti ugašeni
- postoji opasnost od Backdraft efekta, tj. uslijed usporavanja izgaranja plinova zbog nedostatka kisika, te ponovnim naglim uvođenjem kisika u nestabilni, skućeni prostor, može prouzrokovati ponovni požar.

Backdraftov efekt pojavljuje se kao najgori mogući scenarij kada pirolitički plinovi nastali uslijed nedostatka kisika te uslijed ponovnog dotoka svježeg zraka stvore gorivu mješavinu i budu zapaljeni. Uslijed zapaljenja dolazi do eksplozivnog izgaranja i ekspanzije plamenih mlazova kroz različite otvore. Cijeli eksplozivni efekt je kratkotrajan, ali može biti vrlo poguban, pogotovo za ljude.

Karakteristićni znakovi Backdraft efekta su žuti ili smeđi dim, koji izlazi kroz male otvore kao što su rubovi vrata ili prozora. Tamna boja dima uzrokovana je prisutnošću velikih kolićina čestica suspendiranih u zraku prostora zahvaćenog požarom zbog nepotpunog izgaranja kao znak nedovoljne kolićine kisika.



Slika 40: Shematski prikaz tijeka požara

Ukoliko se iskljući početni period iniciranja požara tada je period rane faze i potpuno razvijenog požara kraći od vremena slabljenja požara, odnosno njegovog gašenja. Odnos trajanja pojedinih perioda u većini slučajeva je u omjeru  $1/3$  naspram  $2/3$ .

### 3.3. Analiza požara u brodskim strojarnicama

Vatra je jedan od glavnih uzroka gubitka broda. Statistički gledano na požare i eksplozije otpada jedna četvrtina ukupnih pomorskih nezgoda. Iako uz veliki tehnološki napredak broda i brodske opreme te mnoge izmjene Solas konvencije u dijelu protupožarne zaštite, doprinos sigurnosti broda još uvijek nije dostatan. Tehnologija i oprema na brodovima danas su toliko različite u odnosu na prije nekoliko desetljeća

Vatra na brodovima je vrlo opasna za život ljudi. Zbog toga se i inzistira na povećanoj sigurnost od požara poboljšanjem dizajna broda i korištenjem novih naprednih tehnologija. Danas je u svijetu opće prihvaćeno da su ljudski životi najviši prioritet u zaštiti na brodu, ne samo u vezi požarnih incidenata, već i ostalih incidenata koji bi mogli ugroziti ljudski život kao npr. sudar brodova.

Većina SOLAS propisa o zaštiti od požara bavi se zaštitom ljudskih života, zatim zaštitom okoliša, a tek onda zaštitom imovine, tj. broda.

Bez obzira na navedeni redoslijed prioritetne mjere zaštite od požara koje trebaju biti redoslijedom su:

- rano otkrivanje požara
- zadržavanje i čuvanje vatre pod kontrolom
- alarm
- evakuacija
- raspoređivanje / gašenje požara / ventilacija dima.

Tradicionalno, zaštita od požara na brodu može se podijeliti u 3 skupine i to:

- strukturna zaštite od požara
- vatrodjava
- gašenje požara.


Osim naziva strukturna zaštitu od požara neki koriste i naziv pasivna zaštitu zbog njegove pasivne karakteristike. Ciljevi strukturne zaštite od požara su usporiti širenje vatre na brodu i dati ljudima dovoljno vremena da se sklone ili pobjegnu ili, u najgorem slučaju stići do splavi ili plovila za spašavanje kako bi spasili vlastiti život.

SOLAS 74 daje 8 osnovnih načela zaštite od požara na brodovima s više detalja u poglavlju II-2, uredbe 2.

Ta su načela kako slijedi [47] [48]:

- 1) podjela broda po glavnim vertikalnim zonama toplinskim i strukturnim granicama
- 2) odvajanje smještajnih prostora od ostatka broda toplinskom i strukturnom granicom
- 3) ograničena upotreba zapaljivih materijala
- 4) otkrivanje požara u zoni podrijetla
- 5) zadržavanje i gašenje vatre u prostoru podrijetla
- 6) zaštita bijega ili pristupa za gašenje požara
- 7) dostupnost aparatima gašenje požara
- 8) minimiziranje mogućnosti zapaljenja para zapaljivog tereta.

Statistika pokazuje da je za većinu požarnih incidenata razlog ljudska pogreška – iznosi otprilike 80 % ukupnih požarnih pomorskih nezgoda. Grafikon 3. demonstrira stupnjeve gubitka, uzrokovane požarima strojarnice za razdoblje od 1991. do 1996., i to potonuća ili konstruktivnog gubitka (CTL) 20 %, velikih požara 41 % i malih incidentnih požara 39 %. Više od 60 % požari strojarnice uzrokuju velike štete broda.




Grafikon 3: Prikaz postotka gubitka s obzirom na jačinu požara

Izvor: <http://www-pub.iaea.org/>

Grafikon 4. prikazuje požare u strojarnicama prema vrsti plovila na kojem su se dogodila. Oko 42 % svih požara strojarnice se dogodilo na općim teretnim brodovima, 16,5 % na tankerima i 15,8 % na Ro-Ro brodovima.






Grafikon 4: Postotak broja požara prema vrsti plovila

Izvor: <http://www-pub.iaea.org/>

Godine 1994. Japansko klasifikacija društvo objavilo je rezultate istraga 73 požara koji su se dogodili na brodovima u istoj klasi za razdoblje od 1980. do 1992. Grafikon 5. prikazuje uzroke požara strojarne i to 43 % gorivo, podmazivanje uljem 11 %, otpadna ulja 3 %, 26 % je rezultat električnog kvara, 10 % od popravaka, zavarivanja i slično.



Grafikon 5: Postotak učestalosti uzroka požara strojarne

Izvor: <http://www-pub.iaea.org/>


Grafikon 6. demonstrira učestalost požara grupiranih po težini i razvrstani po starosti plovila. Znatno broj požarnih incidenata dešavao se tijekom prve godine eksploatacije broda. Ali osim prve godine, vrhunac požarnih incidenata događao se u razdoblju od 16. do 24. godine starosti broda, odnosno njegove eksploatacije.



Grafikon 6: Učestalost požara – grupirano po težini i razvrstano po starosti plovila

Izvor: <http://www-pub.iaea.org/>

Sljedeći grafički prikaz (7), demonstrira broj žrtava koje su se dogodile u razdoblju od 1977. do 1996., prema vrsti plovila i mjestu požara. Iz grafikona je vidljivo da je najviše nastanka ozbiljnih požarni incidenata bilo u prostorijama strojarnice, zatim teretnim prostorima i na kraju smještajnim područjima, što logično dovodi do zaključka da je najveći broj žrtava uslijed požara bio u brodskoj strojarnici.



Grafikon 7: Broj žrtava – navedeno po vrsti plovila i razvrstano prema mjestu događaja

Izvor: <http://www-pub.iaea.org/>

---

#### **4. NOVE ELEKTRONIČKE I RAČUNALNE TEHNOLOGIJE U BRODSKIM VATRODOJAVNIM SUSTAVIMA**

Sve veći zahtjevi današnjih brodovlasnika za smanjenjem rizika i sigurnosti plovidbe, potaknulo je proizvođače brodske opreme i znanstvenu zajednicu na razvoj i implementaciju novih konceptualnih rješenja. Opasnosti od požara mogu dovesti do katastrofalnih posljedica uzrokujući velike materijalne štete, za brod i brodske sustave, brodski teret, gubitak ljudskih života, također i štetu za okoliš, odnosno njegov ekosustav. Kao rezultat toga, danas je zaštita od požara jedan od glavnih prioriteta u dizajniranju broda, a posebno se to odnosi na putničke brodove. IMO pravila i propisi zaštite ljudskih života na moru (SOLAS - konvencija) pružaju okvirnu zaštitu od požara.

Uvođenjem brodske automatizacije pokušava se povećati pouzdanost, sigurnost i funkcionalnost brodskih sustava, pa tako i sustava detekcije dojave požara. Tijekom zadnjeg desetljeća razvojem brodske automatizacije, razvijali su se i napredni sustavi za automatsko otkrivanje dima i požara na brodu. To se postiglo mnogim naprednim istraživanjima kako u komercijalne tako i u vojne svrhe, gdje prednjači mornarica SAD-a uvođenjem robota opremljenog s naprednom tehnologijom u sustav za rano otkrivanje mogućih žarišta. Od sustava za detekciju požara koji je tehnološki vrlo zahtjevan, očekuje se visoka pouzdanost i preciznost u njenom ranom otkrivanju. To je utjecalo i natjeralo industriju na razvijanje multisenzorskog pristupa, odnosno novih pametnih multisenzora, zatim usavršavanje upotrebe videotehnike (CCTV kamera) u ranom otkrivanju dima i vatre, stvaranje novih algoritama, iako već postoji veliki broj razvijenih starih, primjenu fazi logike u sistemima za detekciju požara, pa i samih detektora, a sve s ciljem što uspješnije detekcije vatre i dima na brodu, u najranijoj fazi njenog nastajanja, kada su očekivane štete najmanje.

##### **4.1. Značaj Solas propisa II-1/8-1, II-2/21 i II-2/22 za razvitak tehnologije vatrodojave**

Izgradnjom sve većih putničkih brodova u zadnjem desetljeću, uz povećanje broja putnika, narasla je zabrinutost s aspekta rizika sigurnog povratka u luku, kako broda tako i putnika. Zbog toga je tim Međunarodne pomorske organizacije (IMO), odnosno Odbor za pomorsku sigurnost na 82. sjednici krajem 2006. preispitivao sigurnosti putničkih brodova u

-----

izvanrednim situacijama, u svrhu poboljšanja, odnosno stvaranja novih koncepata brodskih sustava, pa tako i sustava dojava požara koji će pružiti veću sigurnost, te su donesene izmjene i dopune novih SOLAS propisa, II-1/8-1, II-2/21 i II-2/22, za nove brodove dulje od 120 metara ili imaju tri ili više požarnih zona, s početkom primjene 2010.g. Izmjene i dopune se odnose na redundanciju brodskih sustava uzrokovanih pravilima sigurnog povratka broda i putnika u luku, a koja pruža sigurnost i sposobnost sustava da nastavi svoju funkciju izbjegavanja zastoja i onda kada neka od komponenata u lancu tog sustava po novim propisima zataji.

SOLAS propisi II-1/8-1, II-2/21 i 22 izmijenjeni i dopunjeni utvrđuju tri scenarija i to [49]:

- dostupnost bitnih sustava nakon nezgode uzrokovane poplavom, u skladu sa SOLAS uredba II-1 / 8-1
- dostupnost bitnih sustava za potporu sigurnog povratka broda u luku nakon nezgode uzrokovane požarom, u skladu sa SOLAS regulacijom II-2/21
- dostupnost bitnih sustava za potporu brodskoj evakuaciji nakon incidenta izazvanog požarom, u skladu sa SOLAS regulacijom II-2/22.

Navedenim izmjenama SOLAS propisa postiglo se da nakon otkrivanja uzroka nezgode na brodu, a koja može biti naplavljivanje broda ili požar, utvrđuje granični prag nezgode. Ukoliko je nezgoda prouzrokovala oštećenje veće ili manje od graničnog praga tada se pristupa ili sigurnom povratku u luku, ili se vrši evakuacija.

Prema SOLAS propisima (Reg. II-2/21) sustavi koji moraju osigurati minimalno operativno funkcioniranje broda u slučaju oštećenja su [50]:

- propulzijski sustav (u slučaju naplavljivanja ili požara mora raditi jedan osovinski vod)
- kormilarski sustav (više razine upravljanja)
- alternativni sustav (azipod - pogonska jedinica sastavljena od kućišta i u njemu smještenog električnog pogonjenog vijka)
- elektroenergetski sustavi (osigurati energiju za sve potrebne sustave)
- vanjski komunikacijski sustav
- interni komunikacijski sustav, uključujući sustav brodskog razglasa
- navigacijski sustav

- 
- protupožarni sustavi
  - balastni sustav i sustav kaljuže (za svaku zonu rad sustava mora biti neovisan o oštećenju ostalog dijela sustava)
  - vodonepropusna vrata
  - sustav dojave naplavljivanja
  - svi ostali sustavi važni u funkciji upravljanja i kontrolu nastale štete.

Danas su pojedine tvrtke već razvile jedinstvene softverske alate za obavljanje ukupnih i detaljnih analiza sustava koji podliježu SOLAS propisima sigurnog povratka u luku. Jedan takav softverski alat je ISYS koji omogućuje modeliranje međusobno povezanih složenih brodskih sustava i njihovih komponenata [87]. To je učinjeno geometrijskom podjelom plovnog objekta, korištenjem jednostavnih logičkih izraza koji definiraju njihovu međusobnu ovisnost. Po IMO propisima softver ISYS omogućava sustavima vršenje analize mogućih scenarija na osnovi ulaznih podataka te na osnovi tih podataka mogući prag štete. Sustav automatski generira podatke, koji se mogu koristiti i za izradu dokumentacije operativnih postupaka za brodsku posadu.

#### **4.2. Integracija sustava dojave požara u brodski integrirani sustav**


Integracijom brodskih sigurnosnih sustava u koji spadaju i integrirani sustavi vatrodajave kao što su alarmni sustav detekcije požara, sustavi za gašenje požara na brodu i sustav videonadzora u otkrivanju dima i plamena, odnosno početak požara te brodskog alarmnog sustava, kroz horizontalnu i vertikalnu integraciju i komunikaciju uporabom dvostruke brodske računalne mreže, a sve zajedno ostvarenom satelitskom komunikacijom s centralnim računalom brodarka na kopnu, uvelike se povećava sigurnost i zaštita broda pri navigaciji, manevriranju i upravljanju. Većina današnjih brodskih požara, na brodovima za prijevoz tereta nastaje u strojarnicama, dok na putničkim u nadgrađu, zbog čega SOLAS propis Ch.II-2/Reg.4 obuhvaća mjere zaštite za sprječavanje izbijanja takvih požara. Poštivanje pravila i propisa provjeravaju klasifikacijska društava i lučke kapetanije.

Integracija sigurnosnih funkcija podrazumijeva:

- otkrivanje i zaštitu od požara
- otkrivanje i zaštitu od plina

- postrojenja za gašenje požara
- integritet voda, stabilnost računanja
- zaustavljanje u nuždi ventilacije i strojeva
- CCTV video sustav
- iscertan sigurnosni plan zaštite
- interaktivne postupke u slučaju opasnosti.

Slika 46 prikazuje integraciju vatrodajavnog sustava u brodski integrirani sustav, a sve u svrhu što bržeg i učinkovitijeg suzbijanja požara.

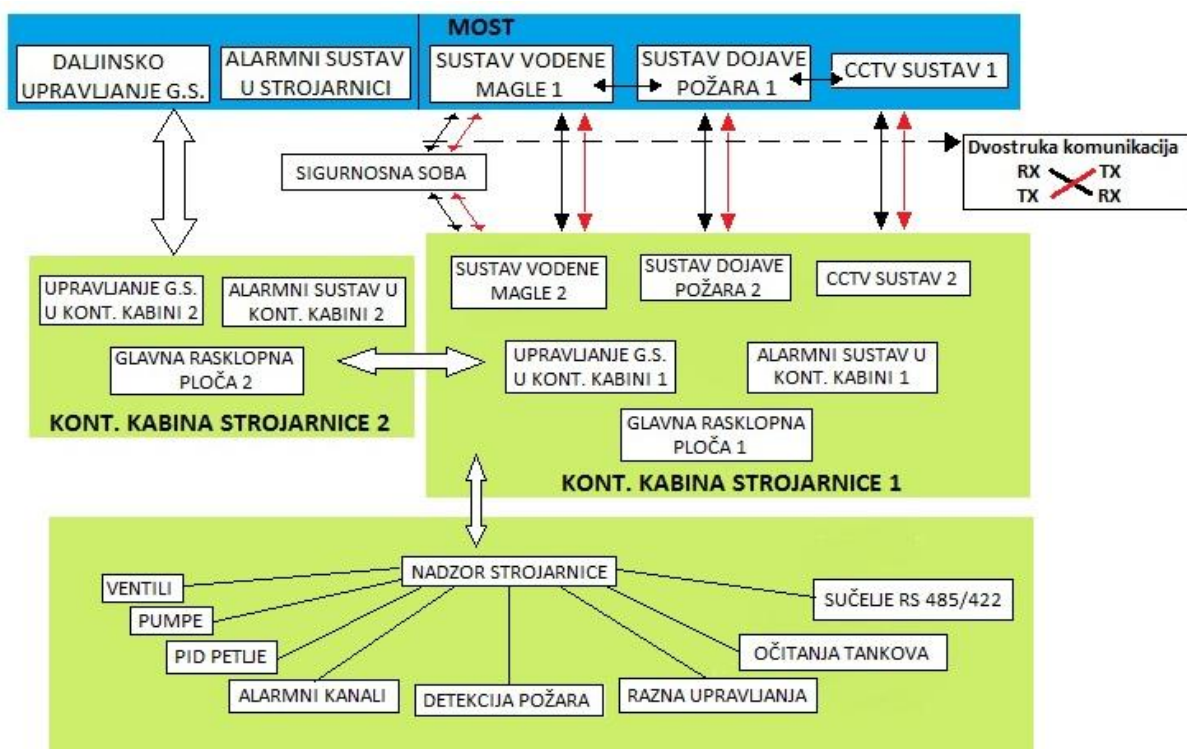


Slika 41: Arhitektura međuveza vatrodajavnih sustava i njihova integracija u brodski integrirani sustav

Centraliziranje svih sakupljenih podataka inicirat će odgovarajući preventivni odgovor u što kraćem vremenu. Napredak tehnike gašenja požara na brodu pomoću vatrodajavnih sustava uvjetovao je sposobnost alarmnog sustava vatrodajave i to na:

- sposobnost automatskog lociranja žarištu požara
- sposobnost automatskog ocjenjivanja veličine požara i stupnja ugroženosti

- sposobnost automatske primjene adekvatnog odgovora
- učinkovit sustav supresije čiji rad ima mali utjecaj na bilo što drugo osim na vatru
- centralizirano i osjetljivo odlučivanje putem broškog integriranog sustava.



Slika 42: Prikaz visoke redundancije prema SOLAS propisima sigurnog povratka u luku

### 4.3. Primjena višekriterijske tehnologije u otkrivanju požara

Primjena višekriterijske tehnologije u otkrivanju požara započela je uvođenjem adresabilnih analognih detektora. Napretkom elektronike i mikroprocesora u sklopu sustava vatrodajave, prvi adresirani inteligentni detektori bili su praćeni i kontrolirani od strane centralne jedinice. Daljnji razvoji mikroprocesora i elektronike omogućili su stvaranje inteligentnih detektora, gdje se obrada podataka može vršiti u samom detektoru, neovisno o kontrolnoj centralnoj jedinici.

Treba napomenuti da je veliki dio istraživanja višekriterijske tehnologije u otkrivanju požara bio usmjeren na razvoj algoritama koji koriste neizrazitu logiku i neuronske mreže za klasifikaciju događaja između požara i izvora smetnji.

Ideju napredne fazi logike (neizrazite logike) prvi put je usavršio profesor dr. Lotfi Zadeh sa Sveučilišta Berkeley, Kalifornija 1960. godine. Danas je općenito mišljenje da je fazi logika nastala kao profitabilan alat za upravljanje i kontrolu raznim sustavima i aplikacijama. Kod sustava vatrodajave algoritmi intenziteta svjetlosti, gustoće dima, vlažnosti i temperature, djeluju kao fazi ulazne varijable na osnovi kojih izlazna varijabla donosi sud vjerojatnosti događanja vatre.

Zbog mogućih grešaka i nepreciznosti javljača požara, mnogi proizvođači sustava dojave požara koriste logiku preispitivanja signala javljača očitavanjem tri i više puta, te nakon potvrde istinitosti dopušta se ulaznom signalu daljnje djelovanje. Detekcija požara bazira se na varijablama i to [51]: dimno zamračenje (gustoća dima) ( $S$ ), brzina promjene dimnog zamračenja ( $\Delta S$ ), temperatura ( $T$ ), brzina promjene temperature ( $\Delta T$ ), boja plamena ( $P$ ). Većinom, prilikom istraživanja najčešće se koriste tri vrijednosti varijabli, niska, srednja i visoka. Što je više vrijednosti varijabli i krajnji rezultat ispitivanja bit će točniji. Tablica 10 prikazuje deset fazi pravila otkrivanja mogućnosti nastanka požara.

Tablica 10: Prvih deset fazi pravila za otkrivanje požarnih problema

Br.	Temperatura	Dim	Svjetlost	Vlažnost	Udaljenost	Izlaz
1	Niska	Slab	Slaba	Visoka	Velika	Vrlo nizak
2	Niska	Slab	Slaba	Visoka	Srednja	Vrlo nizak
3	Niska	Slab	Slaba	Visoka	Mala	Vrlo nizak
4	Niska	Slab	Slaba	Srednja	Velika	Vrlo nizak
5	Niska	Slab	Slaba	Srednja	Srednja	Vrlo nizak
6	Niska	Slab	Slaba	Srednja	Mala	Nizak
7	Niska	Slab	Slaba	Niska	Velika	Vrlo nizak
8	Niska	Slab	Slaba	Niska	Srednja	Nizak
9	Niska	Slab	Slaba	Niska	Mala	Nizak
10	Niska	Slab	Srednja	Visoka	Velika	Vrlo nizak

Izvor: Parul Mohindru, Vikshant Khanna, Rajdeep Singh., Forest Fire Detection Various Approaches., International Journal of Emerging Science and Engineering (IJESE) ISSN: 2319-6378, Vol. 1, Isus 6, 2013.


U današnje vrijeme multisenzor algoritmi za sustav ranog otkrivanja i dojavu požara (MSFDA), jedni su od važnijih aktualnih zbivanja u razvoju brodske tehnologije sustava dojave požara. Stari brodske vatrodajavni sustavi većinom koriste pojedinačne senzore temeljene na jednostavnoj logici odluke. Novi MSFDA algoritam razvijen na temelju fazi



zaključivanja sustava i neuronskih mreža doprinijelo je većoj točnosti donošenja odluke je li se incident dogodio ili nije, odnosno je li sustav otkrio dim ili plamen kao mogući uzrok nastanka požara na brodu.

#### 4.4 Utjecaj nanotehnologije na razvoj vatrodojave

Kao nova tehnološka grana nanotehnologija izravno upravlja nanočesticama, a temelji se na njihovom poznavanju i kontroli. Utjecaj nanotehnologije na temeljne promjene mnogih drugih tehnologija, neće samo poticati tehnološki razvoj, već će imati utjecaj i u ekonomiji, ekologiji i sociologiji. Ona se bavi materijalima i procesima čija je veličina milijarditi dio metra, zbog čega se i veličina izražava u nanometrima. Nanomaterijali su predmet velikog interesa zbog njihove potencijalne široke primjene u različitim područjima.




Grafikon 8: Predviđanje rasta tržišta nanotehnologije do 2010.

Izvor: Credit Suisse, GIA

Općenito postoje tri vrste nanomaterijala jednodimenzionalni (1D), dvodimenzionalni (2D) i trodimenzionalne (3D). Područje istraživanja nanomaterijala brzo se širi i raste.

Pojedini znanstvenici smatraju da je revolucija u nanoznanosti započela 1981. godine pronalaskom naprave *scanning tunneling microscope* (STM) za čiji pronalazak su Heinrich Rohrer i Gerd K. Binning iz IBM-a, Zürich, godine 1986. dobili Nobelovu nagradu za fiziku. Interes za nanotehnologiju naglo je porastao u razvijenim zemljama, prije svega u SAD-u, Europi i Japanu, a poslije i u Kini.



Grafikon 9: Učešće tržišta za nanotehnologiju u 2008. godini

Izvor: Credit Suisse, GIA

Procjena je da se samo u SAD-u u 800 pogona, proizvodi više od 700 tipova nanomaterijala, od kojih su mnogi već u svakodnevnoj upotrebi. Jedno od najvažnijih postignuća nano-tehnologije koje najviše obećava je ugljična nanocijev čija je čvrstoća i do 100 puta jača od čelika.

U kontekstu nanotehnologije, elektronika ima dvostruko značenje, jer je istovremeno elektronika pokretač nanoznanosti bez koje se ne bi moglo istraživati male dimenzije, te je ujedno grana znanosti i tehnologije u kojoj je primjena otkrića nanoznanosti vrlo velika [52].

Najvažnije primjene nanoelektronike su u području obrađivanja i prenošenja podataka elektroničke, optičke i optoelektroničke komponente. Uz to očekuje se da će nano tehnologija dovesti do snižavanje cijena i većih preciznosti procesa u području tehnologija izrade spomenutih komponenata. Istovremeno nanotehnologija nudi nove koncepte temeljene na iskorištavanju kvantno-mehaničkih učinaka za postizanje manjih, bržih, otpornijih ili na bilo koji drugi način boljih komponenata. Upotreba nanotehnologije u području informacija i komunikacija doprinosi se razvoju novih arhitektura kvantnih računala što dovodi do potpuno novih razina računalnih snaga [53]. Već su u upotrebi nanometarski tranzistori, diode, releji, logička vrata, spojni vodovi od organskih molekula, ugljikovih nanocijevi i poluvodičkih nanocijevi. Koristeći nanotehnologiju također su proizvedeni svijetleći uređaji i displeji. S obzirom na svojstva, u budućnosti će nanocijevi biti korištene kao vodiči topline i za vođenje velikih struja.

-----

Kada govorimo o utjecaju i primjeni nanotehnologije u vatrodojavnim sustavima, ona se danas primjenjuje u proizvodnji raznih komponenata alarmnih vatrodojavnih sustava kao što su mikroprocesori, RAM memorije, minijturni senzori, ali isto tako i u proizvodnji materijala i zaštitnih premaza otpornih na visoke temperature.


#### **4.5. Upotreba svjetlovodnog kabela u sustavu vatrodaje**

Optička vlakna naširoko se koriste za prijenos podataka i fizička istraživanja. U pogledu fizičke aplikacije, optička vlakna mogu se koristiti za otkrivanje varijacije u temperaturi pomoću indeksa loma svjetlosnog snopa i izmijenjenih geometrijskih svojstva. Svjetlovodni kabel kao detektor temperature prvi put je uporabljen u vatrodaji u kasnim 1980-im. Za razliku od konvencionalnih detektora požara, svjetlovodni detektor temperature koristi cijelo optičko vlakno kao medij za očitavanje. Svjetlovodni detektor temperature mjeri temperaturu u rasponu od -160 do 600 °C, a ponekad i više [54].

Jedan od najsuvremenijih vatrodajavnih sustava zasnovan na uporabi svjetlovodnog kabela kao detektora je sustav koji koristi optički vodič s laserskim izvorom svjetla. Princip rada detektora baziran je na izmjeni parametara laserskog snopa uzrokovanog deformacijom vodiča. Uslijed širenja cijevi ispunjene voskom zbog rasta temperature optički vodič se deformira. Suprotno hlađenjem, sve se vraća u pravilan oblik prethodnih dimenzija. Logička sektorizacija kabela izvodi se prije početka upotrebe vatrodajavnog sustava. Sektorizacija pomoću pripadajućeg programa omogućava određivanje mjesta požara velikom preciznošću, uz definiranje zone zahvaćene požarom, smjera djelovanja i brzine napredovanja požara. Sustavi ovakvog tipa za sada najviše se upotrebljavaju u cestovnim tunelima, zračnim lukama, komunalnim tunelima, rafinerijama [55]. Postoje naznake korištenja sustava i na brodovima za prijevoz automobila.


Trenutno na tržištu ovakav je tip kabela skup, zbog čega još nije u uporabi u brodogradnji, iako bi bio idealan kod brodova za prijevoz automobile s više paluba. Moguće je da u budućnosti ova vrsta svjetlovodnog detektora u obliku vatrodajavnog integriranog kruga bude znatno jeftinija te se koristi i na brodovima. Optički kabel uz mjerenje maksimalno određene temperature mjeri i gradijent temperature.

Drugi pristup svjetlovodnog detektora je princip gdje je osjetilo pohranjeno na kraju kabela, a radi na principu fazne razlike dvaju svjetlosnih snopova [56].



Slika 43: Svjetlovodni detektor temperature na principu fazne razlike dvaju svjetlosnih snopova

Treći pristup korištenja svjetlovodnog kabela kao detektora temperature je princip korištenja bimetalne trake gdje pri promjeni temperature okoline dolazi do savijanja trake prema svjetlovodnim vlaknima, dovoljno za generiranje mjerljivih fizikalnih promjena [57].



Slika 44: Svjetlovodni detektor temperature pomoću deformacije vlakna


izvor: <http://www.capgo.com/Resources/Temperature/FibreOptic/Fibre.html>

Karakteristike sustava sa svjetlovodnim kabelom su:

- jednostavnost instalacije
- pouzdano brzo otkrivanje temperature LHD (Linear Heat Detection) tehnologijom
- neosjetljivost na elektromagnetske utjecaje, vibracije, vlažnost, promjene temperature
- velika otpornost na mehaničke utjecaje, gomilanje prašine i nečistoća, razne kemikalije
- vlakno je potpuno pasivni senzor i ima vrlo dug vijek trajanja

- nema elektronike ili pokretne dijelove
- mjerenja temperature su predviđene preko ukupne dužine osjetilnog kabela.

Inače, svjetlovodni linearno-temperaturni detektori koji funkcioniraju preko modulskog distributera temperaturnog senzora ( DTS ), koriste optička vlakna kao detektor.



Slika 45: Laserski detektor

Izvor: [https://eng.ucmerced.edu/How\\_DTS\\_works.pdf](https://eng.ucmerced.edu/How_DTS_works.pdf)

Ovaj sustav zvan *firelaser*, može ispitati temperaturu na svakom intervalu od 1 metra duž instaliranog optičkog kabla do 4 km po krugu s temperaturom rezolucije boljom od 1 °C. Sustav pruža niz alarmnih stanja kao što su maksimalne temperature praga, temperatura stope rasta praga i odstupanja temperature [58].

#### 4.6. Uvođenje robotike u otkrivanju dima i plamena

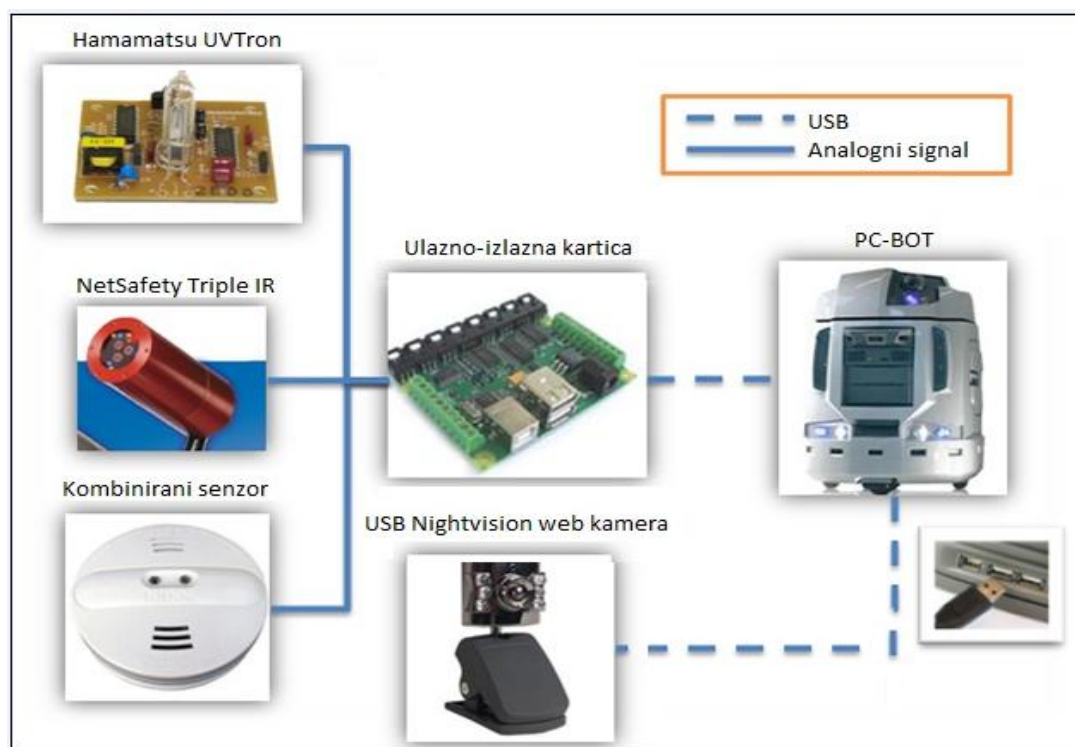
Kako bi se smanjili troškovi nastali zbog šteta uzrokovanih požarom, a također i količinu lažnih uzbuna, američka mornarica imala je potrebu baviti se istraživanjem za poboljšanu tehnologiju detekcije požara. Istraživanjem je utvrđeno da se korištenjem autonomnog robota opremljenog s naprednom tehnologijom detekcije požara mogu smanjiti troškovi i reducirati lažni požarni alarmi na brodovima američke mornarice. Glavni cilj istraživanja bio je razvijanje preciznost sustava detekcije požara koji minimizira lažne alarme ispod 25 %, i radi u sklad s postojećim centraliziranim požarnim alarmnim sustavom.

U pogledu ograničenja, navigacijski aspekt robota imao je tri glavna ograničenja. Pokrivenost područja detekcije, prosječnu brzinu od 500 cm/s te potrebnu relativno ravnu površinu putovanja robota, odnosno ravnu površinu izbjegavajući sve statičke i dinamičke

prepreke usmjerene na put robota. Također, za bitnu komunikaciju potrebno je da nema ograničenja za Wi-Fi pristupne točke, odnosno pristupnost Wi-Fi signala.

Sustav za otkrivanje požara koji je predložila američka mornarica sastojao se od četiriju senzora montiranih na vrhu PC-robotu i usmjerenih u smjeru puta robota. Najmanji kut gledanja svih senzora, osim za detektor dima je  $90^0$ . Ako su ti senzori postavljeni jedan do drugoga, problem nastaje u vidnom polju svakog senzora. Zbog toga senzori se postavljaju vertikalno. Postupak integracije senzora u ukupni robotski sustav prikazana je na sljedećoj slici (46).

Analogni izlazi UV detektora plamena i Triple IR detektora plamena izravno su spojeni preko I/O kartice na PC-BOT kako bi se signali na računalu pretvore u čitljive digitalne signale. Detektor dima također je povezan preko I/O kartice s PC-BOT-om, dok je Web kamera izravno povezan s PC-BOT-om preko USB 2.0 priključka.



Slika 46: Integracija senzora detekcije požara s robotskim sustavom

Izvor: <http://www.eng.uwaterloo.ca/>

Analizirani su rezultati studije istraživanja američke mornarice o korištenju robota u otkrivanju dima ili plamena na brodovima te se pokazalo da su u otkrivanju stvarnih požara postignuti zavidni rezultati, ali ograničen uspjeh u smanjenju stopa lažnih alarma.

---

#### 4.7. Korištenje termovizije za rano otkrivanje potencijalnog žarišta požara

Infracrveno (IC) zračenje otkrio je fizičar Sir William Herschel (1738–1822), otkrivajući pomoću teleskopa planet Uran, godine 1800-e zapazio je da svjetlo prolazeći kroz filtre obojane različito, različito zagrijava stvari. Eksperimentom koji je proveo pomoću prizme razlučio je bijelu svjetlost u boje spektra.

Primjena infracrvene termovizije zapravo je započela sredinom šezdesetih godina, kada je firma Aga (danas Flir) proizvela prvu opremu za tu namjenu pod nazivom *Model Thermovision 651*, na osnovi čega je izraz „termovizija” ušao u svakodnevnu upotrebu. Termovizija kao područje znanstvenog istraživanja predstavlja jednu od najbrže rastućih tehnologija ispitivanja i prikupljanja podataka s aspekta očuvanja životne sredine, pa tako i u upotrebi termovizije u ranom otkrivanju potencijalnih žarišta požara na brodovima. Termovizija korištena na brodu značajna je i u dijagnostici stanja ispravnosti brodskih sustava strojarne, koja omogućava detekciju eventualnih oštećenja pojedinih sustava bilo elektroenergetske opreme ili strojarskih sistema koja mogu uslijed povišene temperature uzrokovati požar.

Načini korištenja termovizije su neograničeni. Osnovna pretpostavka na kojoj se termovizija zasniva je da svi objekti iznad apsolutne nule ( $-273\text{ }^{\circ}\text{C}$ ) emitiraju nevidljivi infracrveni spektar zračenja, koji predstavlja funkciju više različitih karakteristika objekta, od kojih se samo jedna odnosi na temperaturu. S povećanjem temperature objekta, raste i intenzitet emitiranog IC zračenja. Infracrveni uređaji (radiometri, IC kamere) ne mjere direktno temperaturu objekta, ali detektiraju energiju zračenja koja predstavlja funkciju temperature. Kao bezkontaktna metoda mjerenja temperature, termovizija se temelji na izmjeru intenziteta IC (infracrvenog) zračenja s određene površine neke stvari ili elementa. Mjerenje temperature na daljinu sadržano je u zakonu fizike, kojim sva tijela zrače određenu energiju [69]:

$$W = f(\varepsilon, T), \quad (4.1)$$

gdje su:


“ $\varepsilon$ ” = koeficijent sposobnosti odašiljanja (emisije) i ovisi o kemijskom sastavu materijala,

“ $T$ ” = temperatura u  $^{\circ}\text{K}$ .



Kako 0 °K odgovara temperaturi od –273,3 °C (apsolutnoj nuli), na toj temperaturi nema zračenja energije. Međutim, smatra se da sve što nas okružuje odašilje određenu količinu toplinske energije.

Infracrveno (IC) zračenje je dio elektromagnetskog (EM) spektra koje počinje ispod vidljivog dijela spektra, a proteže se do preko 200  $\mu\text{m}$ , Za primjenu u praksi termografski IC spektar je u području 2  $\mu\text{m}$  do 13  $\mu\text{m}$  i vidi se kao optička svjetlost.



Slika 47: Spektar elektromagnetskih valova s naglaskom na infracrveno područje

Izvor: [www.odrzavanje.unze.ba/zbornici/2010/047-O10-056.pdf](http://www.odrzavanje.unze.ba/zbornici/2010/047-O10-056.pdf)

Termovizijska ili IC (IR) kamera predstavlja uređaj koji generira sliku na osnovi infracrvenog spektra zračenja. Princip rada odnosi se na to da se infracrveni spektar zračenja, nevidljiv za ljudsko oko, koji emitira neki objekt, prevodi u vidljivu sliku (termogram) na kome se dobiva podatak o temperaturi i klasificiraju se površine koje emitiraju različite količine infracrvenog zračenja (veće zračenje – svjetlije boje), dok iste boje predstavljaju izotermalne površine koje emitiraju jednake količine topline.

Primjena IR kamera usko je vezana za slučajeve gdje promjena termičke slike može ukazati na neku anomaliju. Osnovni dijelovi infracrvene (infrared) kamere su:


- objektiv (sakuplja zračenje)
- filter (propušta zračenje određene valne dužine)
- detektor (očitava zračenje i prevodi ga u elektronski oblik) i
- monitor (elektronički oblik prikazuje kao sliku, tj. termogram).

Termografska kamera preko senzora na osnovi infracrvenog zračenja površine promatranog stvari ili objekta, IC zračenje pretvara u vidljivi prikaz termogram. Kvaliteta odnosno točnost termovizijske slike ovisit će o parametrima termografske kamere. Današnje



termografske kamere imaju razlučivost od 0,1 °C pa sve do 0,01 °C., što je dovoljno precizno za korištenje termovizije za rano otkrivanje požara na brodovima pogotovo u brodskim strojarnicama.

Brodski sustavi u prostoru strojarnice imaju vrlo visoki emisijski faktor što doprinosi i mnogo realnijem prikazu i kakvoći termovizijske slike. Osim vlastitog emitiranog zračenja kamera registrira i reflektirano zračenje koje može biti uzrokom krive termovizijske slike pa ukoliko se želi dobiti realna slika tada se mora eliminirati reflektirano zračenje. Za praktično mjerenje temperature koriste se IC valne duljine između 0,7 um i 20 um. Sljedeća slika (48) prikazuje shematski prikaz općeg termografskog mjerenja [70] [71]:



Slika 48: Shematski prikaz općeg termografskog mjerenja

1-okolinu; 2-objekt; 3-atmosfera; 4-kamera

Prema prikazanoj slici ukupna snaga zračenja može se izraziti formulom

$$W_{tot} = \epsilon \tau W_{obj} + (1 - \epsilon) \tau W_{refl} + (1 - \tau) W_{atm} \quad (4.2)$$


Gdje su:

$\epsilon \tau W_{obj}$  – emisija zračenja od objekta, gdje je  $\epsilon$ - emisija objekta i  $\tau$  – atmosfersko propuštanje


$(1 - \epsilon) \tau W_{refl}$  – refleksija okoline gdje je  $(1 - \epsilon)$  refleksija objekta a  $\tau W_{refl}$  temperatura ambijenta

$(1 - \tau) W_{atm}$  – emisija zračenja iz atmosfere gdje je  $(1 - \tau)$  emisija atmosfere i  $W_{atm}$  temperatura atmosfere.

Prema Međunarodnoj konvenciji za sigurnost života na moru (SOLAS), maksimalne površinske temperatura strojeva, dijelova i komponenata u broškoj strojarnici ne smije prelaziti 220 °C. Kako bi se izbjegla mogućnost paljenja i razvoja požara, sve površine iznad 220 °C moraju biti izolirane. Statistike su pokazale da je većina požara u brodskim strojarnicama uzrokovano propuštanjem goriva ili ulja i njihova dodira ili dospijeća na vruće površine. Za brod nastanak takvog požara imat će teške i skupe posljedice, za teret, posadu i brodarsku kompaniju. Isto tako SOLAS pravila propisuju vrste i zaštite pojedinih brodskih elektroinstalacija, električnih ili elektroničkih komponenata. Upravo SOLAS pravila IC termografiji daju mogućnost svrsishodnog korištenja termovizije u sprječavanju mogućih početnih požara i njegovih posljedica, gdje infracrvene kamere (slike 49, 50, 51), pokazuju toplinsko stanje glavnih i pomoćnih strojnih uređaja, električnih sklopova, elektroničkih sustava i drugih brodskih dijelovi u realnom vremenu.




Slika 49: Termovizija broškog pomoćnog motora

Izvor: [www.google.hr/search?q=termovizija](http://www.google.hr/search?q=termovizija)

Slika 50: Termovizija elektromotora brodske pumpe

Izvor: [www.google.hr/search?q=termovizija](http://www.google.hr/search?q=termovizija)



Slika 51: Termovizija elektrosklopnika

Izvor: [www.google.hr/search?q=termovizija](http://www.google.hr/search?q=termovizija)

Boja i intenzitet plamena ovise o materijalu koji gori, količini zraka, zračnim strujanjima i slično. Isto tako uočena boja plamena ili površine zahvaćene požarom putem termovizije, može poslužiti u svrhu procjene temperature požara . Sljedeća tablica (11) prikazuje odnos boje plamena i temperature [74].


Tablica 11: Procjena temperature požara temeljem boje plamena

BOJA PLAMENA	TEMPERATURA (°C)
svijetlo crvena	480 - 530
tamno crvena	530 - 600
trula višnja - tamna	600 - 650
- srednja	600 - 700
- svijetla	700 - 760
žarko crvena	760 - 815
losos crvena	870 - 930
arančasta	930 - 980
žuta	980 - 1050
svijetlo žuta	1050 - 1150
bijela	1150 - 1250
jasno bijela	1350 -

Izvor: [www.mup.hr](http://www.mup.hr)

Sljedeća slika 52 prikazuje shematski tipičnu konfiguraciju sustava pomoću FLIR A310 termovizijske kamere. Iako analogni video i digitalni I/O izlazi omogućuju da IC kamere djeluju kao samostalni pametni senzor, mnoge aplikacije koriste svoj digitalni tok, preko Ethernet linije za PLC ili PC kontroler.

Koristeći ulazno-signalne temperaturne podatke, PLC ili PC kontroler prati i kontrolira određeni sustav ili objekt i uspoređujući stvarnu temperaturu sa zadanim graničnim alarmnim pragom signalizira alarm zvučno i vizualno. FLIR softver omogućuje računalu istovremeni prikaz do devet slika fotoaparata. Osim gledanja termografskih videoslika, temperaturni podaci mogu biti pohranjeni i korišteni za analizu trendova. Također, temperaturni podaci kao i slike, automatski se mogu poslati na računalo elektroničkom poštom (SMTP) ili FTP protokolom, kad god se dosegne prag upozorenja povišene temperature.



Slika 52: Tipična konfiguracija sustava vatrodojave pomoću termovizijskih kamera

Izvor: <http://www.flir.com/>

Termovizija u kombinaciji s vatrodojavnim alarmnim sustavom umnogome doprinosi sigurnosti i brzini u sprječavanju moguće incidentne požarne situacije, koristeći monitor pomoću kojeg se može brzo i točno locirati požarno mjesto, a vrlo često i uzrok požara.

---

#### 4.8. Primjena računalne inteligencije i računalnog vida

Optičko otkrivanje plamena evoluiralo je tijekom posljednjih 30 godina, dok je otkrivanje pomoću videoslike (VID), novija tehnologija koja je evoluirala zadnjih 10 godina. Izvorno VID tehnologija razvijena je u Europi, međutim prva primjena VID tehnologije na brodu bila je u Americi 2007. godine od strane Američke ratne mornarice[59]. Videodetekcija požara čini značajan doprinos učinkovitosti sustava vatrodojave, osobito što se tiče požara u velikim i na velikim prostorima. Svoju tehnološku primjenu u otkrivanju dima i plamena VID sustav ostvario je u zadnjem desetljeću. Međutim, svoju široku upotrebu realizirao je na kopnu. Na osnovu mnogih znanstvenih istraživanja razvili su se programi koji koristeći pametne algoritme i baze podataka, stvaraju podlogu za moguće korištenje videotehnologije u ranom otkrivanju dima ili plamena na brodu. Tehnologija videodetekcije dima ili plamena (VSD) temelji se na analizi videosignala i daje neke osnovne smjernice što se tiče njegove primjene u sustavima vatrodojave [60]. Uz značajke inteligentnog sustava za rano otkrivanje vatre i dima u stvarnom vremenu VID sustav uz vizualizaciju i osjetljivost, pokriva znatno veći dio broetskog prostora, što za razliku od klasičnih detektora to nije moguće. Zbog sve češćih incidentnih situacija izazvanih požarom donijeti su novi SOLAS propisi s ciljem njegovog sprječavanja nastanka požara ili barem njenog lokaliziranja. Dio propisa odnosi se na modeliranje širenja požara na brodu s ciljem što optimalnih konstruktivnih rješenja zaštite broda od požara

Razvojem informatičkih tehnologija uz primjenu računalne inteligencije, ubrzano se razvija i područje računalnog vida. Računalni vid (engl. computer vision) je grana računalne znanosti koja se kao znanstvena i tehnološka disciplina bavi teorijom izrade i izradom sustava za pribavljanje informacija iz slike, bilo iz jedne ili više fotografija ili videosekvenci. Uz pojam računalni vid postoji i pojam „strojni vid“ (engl. machine vision), međutim ne kao sinonim za računalni vid.

Računalni i strojni vid imaju dosta zajedničkog, ali ipak postoji razlika. Dok se računalni vid temeljni na tehnologiji automatizirane obrade i analize slike, strojni vid se bazira na kombinaciji analize slike s drugim metodama, tehnikama i tehnologijama koristeći ih u automatizaciji i robotizaciji industrije. Zbog primjene u industriji i proizvodnji, strojni vid spada u inženjerske discipline. Računalni vid odnosi se na kamere i računala koja umjesto ljudskih očiju imaju za cilj identifikaciju, praćenje i mjerenje uz pomoć strojnog vida te grafičkom obradom slike uz pomoć računala preraditi je da bude prikladnija ljudskom oku.

-----

Kao područje umjetne inteligencije koja se bavi prepoznavanjem određenog predmeta, glavni zadatak računalnog vida je da se kroz obrađeni skup slika ili videosekvence dobije odgovarajuća trodimenzionalna informacija. D. W. Paterson 1990. godine dao je definiciju umjetne inteligencije, a ona glasi: "Umjetna inteligencija je grana računalne znanosti koja se bavi proučavanjem i oblikovanjem računalnih sustava koji pokazuju neki oblik inteligencije. Takvi sustavi mogu učiti, mogu donositi zaključke o svijetu koji ih okružuje, oni razumiju prirodni jezik te mogu spoznati i tumačiti složene vizualne scene te obavljati druge vrste vještina za koje se zahtijeva čovjekov tip inteligencije"[76].

Računalni vid kao sveobuhvatan predmet privukao je znanstvenike iz različitih disciplina za sudjelovanje u istraživanju, uključujući obradu slika i raspoznavanja uzoraka, automatizacije i robotike, fizike, primijenjene matematike i statistike, umjetne inteligencije i kognitivne znanosti.

S obzirom na temu koja se obrađuje u ovoj doktorskoj disertaciji najveću pozornost posvećuje se području obrade slike. Uspješna detekcija dima, plamena, odnosno vatre, značajno ovisi o izboru algoritma. S obzirom da je korištenje računalnog vida nov pristup u detekciji požara, još uvijek nije nađeno adekvatno rješenje sa stopostotnom učinkovitosti. Postoji veliki broj algoritama razvijeni ili u razviju, koji nude zadovoljavajuća rješenja za određene situacije uz određene uvjete.

Današnji literarno dostupni algoritmi detekcije vatre i dima koji se mogu proučavati su [78]:

- detekcija dima i plamena u realnom vremenu na videu bazirana na wavelet transformaciji
- detekcija dima na temelju boje i dinamičkog obilježja dima
- detekcija plamena i dima u realnom vremenu korištenjem kamere u boji
- detektiranje dima na videu zbog ranog alarmiranja u slučaju vatre
- prepoznavanje i detekcija plamena upotrebom videa
- detekcija požara pomoću videosekvenci uz pomoć statističkog modela boja
- klasifikacija požara pomoću piksela korištenjem fazi logike i statističkih modela boja
- inteligentna detekcija požara u realnom vremenu bazirana na metodi videoobrade
- kompjuterska vizija temeljena na metodi detekciju požara u realnom vremenu



- detekcije vatre i dima u realnom vremenu obradom pokretne slike
- detekcija dima na bazi videoobrade u svrhu ranog uzbunjivanja
- detekcije vatre i dima u realnom vremenu pomoću vizualno računalne metode
- tehnika videoprepoznavanja dima i plamena
- otkrivanja požara u videosekvenci pomoću statističkih modela boja
- tehnika automatskog nadzora požara korištenjem slika sa vidljivim svjetlom.

Videodetekcija požara i dima (VFSD) pojavila se razvojem i primjenom novih elektroničkih i računalnih tehnologija. Tehnike video obradu za automatsku detekciju požara i dima je područje istraživanja koje koristi računalni vid posljednje desetljeće. Tu se najviše misli na korištenje digitalne tehnologije obrade slika. Tablica 12 daje pregled autora i njihovih radova na temu korištenja VFSD tehnike zadnje desetljeće [87].

Tablica 12: Popis autora i godina te tehnika upotrebe detekcije požara i dima

	Detekcija boja	Detekcija objekta u pokretu	Treperenje	Analiza vremenske razlike	Analiza prostorne razlike	Analiza poremećaja	Pod-blokiranje	Vježbe	Čišćenje nakon obrade	Lokalizacija/širenje	Detekcija plamena	Detekcija dima	Godina objavljivanja
W. Phillips III et al. [3]	RGB		X	X				X	X		X		2002
F. Gomez-Rodriguez et al. [4]		X	X		X							X	2002
F. Gomez-Rodriguez et al. [5]		X	X		X							X	2003
T.-H. Chen et al. [6]	RGB/HSI	X			X						X	X	2004
C.-B. Liu and N. Ahuja [7]	HSV		X		X						X		2004
B.U. Toreyin et al. [8]	YUV	X	X	X								X	2005
B.U. Toreyin et al. [9]	YUV	X	X		X							X	2006
B.U. Toreyin et al. [10]	RGB	X	X	X							X		2006
G. Marbach et al. [11]	YUV		X		X						X		2006
Z. Xu and J. Xu [12]		X	X		X						X	X	2007
T. Celik et al. [13]	RGB	X			X			X	X		X		2007
T. Celik et al. [14]	YCbCr/RGB/HSV										X	X	2007
B. Lee and D. Han [15]	RGB	X						X	X		X	X	2007
Z. Xiong et al. [16]		X	X		X							X	2007
P. Piccinini et al. [17]	RGB	X	X					X				X	2008
P.V.K. Borges et al. [18]	RGB				X						X		2008
S. Calderara et al. [19]	RGB	X	X			X	X					X	2008
F. Yuan [20]	RGB	X	X			X						X	2008
F.-X. Yu et al. [21]	RGB	X									X		2008
X. Qi and J. Ebert [22]	RGB/HSV		X	X					X		X		2009
R. Yasmin [23]	RGB/HSI	X			X	X				X		X	2009
J. Gubbi et al. [24]		X	X			X	X			X		X	2009
C. Yu et al. [25]		X	X				X					X	2010
S. Calderara et al. [26]	RGB	X	X			X				X		X	2010
<b>Proposed Method</b>	<b>RGB</b>	<b>X</b>	<b>X</b>	<b>X</b>			<b>X</b>	<b>X</b>	<b>X</b>	<b>X</b>		<b>X</b>	

Izvor: [www.ijicic.org/11-03010-1.pdf](http://www.ijicic.org/11-03010-1.pdf)

---

#### 4.8.1. Modeliranje širenja požara u brodskoj strojarnici

Mnogi znanstvenici uložili su velike napore u izučavanju nastanka požara i njegovog širenja u strojarnicama i nadgrađu koristeći razne softverske alate. Modeliranje ponašanja požara obuhvaća i modeliranje intenziteta nastalog požara na određenom modelu broda.

U projektnoj fazi nastanka broda u modeliranju mogućih incidenata požara poduzima se niz djelatnosti kao što su planiranje požarnih zona, planiranje položaja senzora, količina i tip senzora radi pokrivenosti određenog prostora s obzirom na visinu, širinu i preglednost, ventilaciju i ventilacijske otvore usisa i isisa zraka pogotovo u prostoru strojarnice, poziciju i količinu propuha, materijalu građenja itd. Dobivene vrijednosti postignute modeliranjem služe kao podloga u izboru odgovarajućeg vatrodojavnog sustava i vrste potrebnih detektora, ali isto tako i za modeliranje odabira sustava automatskog gašenja požara određenog broetskog prostora. Model širenja požara u broetkom prostoru pretežitoo ovisi o uvjetima prostora (vlažnost, toplina), mjesta nastanka požara, vrsti goriva, ulja ili maziva u tome prostoru, materijala u okruženju. Sam model širenja požara temelji se na proizvodnji topline i njenog širenja, prijenosa s gorućeg na nezapaljeni materijal čime on postaje novi izvor topline i vatre.


Neki od simulacijskih programa modeliranja vatre su:

- FDS (Fire Dynamics Simulator) – dinamički simulator vatre
- FSSIM (Fire and Smoke Simulator) – simulator vatre i dima
- CFAST (Consolidated Model of Fire and Smoke Transport) – konsolidirani model širenja požara i dima
- ASCOS (Analysis of Smoke Control Systems) – analiza regulacije dima
- ASPIRE SDS (Aspire Smoke Detection Simulation) – simulacija detekcije dima
- BRANZFIRE – model za predviđanje fenomena požara u gornjim i donjim slojevima.

CFAST kompjutorski model (konsolidirani model širenja požara i dima) koristi se za predviđanje stanja kao što su raspodjela dima, količina gorivih plinova i temperatura vatre u određenim prostorima. Osnova CFAST matematičkog modela su masa, zamah i očuvanje energije i jednadžba stanja idealnog plina.



CFAST model je razvijen za analizu prijenos topline zračenjem kroz čvrste barijere koje razdvajaju odjeljke, kao što su pod, strop i periferni zidovi. Ishodi modela CFAST u odnosu na brojne podatke o požaru dobivene simulacijom požara u malim i velikim prostorima, pokazale su odstupanja od nekoliko posto za većinu varijabli. Marko Perković u svom radu [94] koristio je CFAST model za prikaz scenarija i model vatre u brodskoj strojarnici, a kao slučaj požara u brodskoj strojarnici korištena je eksplozija u kućištu motora. Model se temelji na vatri koja se širi iz motora u prostor strojarnice. Upravo ovakva istraživanja mogućih scenarija požara u brodskoj strojarnici i njegovih katastrofalnih posljedica utjecali su na razvijanje i primjenu novih tehnika i informacijskih tehnologija za rano otkrivanje požara na brodovima, gdje spada i upotreba VID tehnologije, odnosno računalnog vida. Slika 53 prikazuje poprečni presjek broda i brodske strojarnice gdje je smješten glavni pogonski stroj u svrhu modeliranja pomoću CFAST računalnog modela.




Slika 53: Podjela brodske strojarnice u 9 zona za CFAST model rasta požara

Izvor: <http://proceedings.asmedigitalcollection.asme.org/proceeding.aspx?articleid=1580263>

Analiza dobivenih rezultata pomoću CFAST računalnog modela je pokazala da je CFAST računalni model prikladno sredstvo za procjenu sigurnosti broda od požara tijekom plovidbe [94].


Pojedini instituti i visoka učilišta kao što je Visoka škola za mornarička istraživanja (US College Fo Naval Research) bave se zakonima dinamičkog kretanja dima u brodskom prostorima pa tako i prostoru brodske strojarnice. Liang Wang i Shichuan Su svojim znanstvenim radom [99] [100], doprinijeli su boljem shvaćanju potreba modeliranja kretanja, širenja i koncentracije dima u višeslojnim i jednoslojnim strukturama strojarnice broda za prijevoz rasutog tereta.

Za simulaciju procesa razvijanja požara u brodskoj strojarnici koristili su FDS program (Fire Dynamics Simulator) – dinamički simulator vatre.



Slika 54 : Raspodjela modela višeslojne geometrijske strukture

Izvor: <https://www.researchgate.net/publication/282280615>



Slika 55: Raspodjela dima u višeslojnoj i jednostrojnoj strukturi

Izvor: <https://www.researchgate.net/publication/282280615>


Kao glavni uzrok nastanka požara navodi se curenje dizelskog goriva iz sustava goriva. Analizom se došlo do zaključka da je štetnost vatre u višeslojnoj strukturi veća nego što je u slučaju jednostrojne konstrukcije. Istovremeno, rezultati tradicionalnog procesa istraživanja pokazuju značajna odstupanja. Također su zaključili i da je brzina širenja dima u višeslojnim strukturama veća nego u jednostrojnima. Oba prikazana modela širenja dima u brodskoj strojarnici bitna su kod brodova koji imaju jako izražen visoki strop (brodovi za prijevoz rasutog tereta, tankeri, brodovi za prijevoz ukapljenog plina, brodovi za prijevoz automobila i drugi) uslijed čega treba i dosta vremena da bi dim aktivirao određeni dimni detektor.

#### 4.8.2. Uporaba računalnog vida za detekciju plamena

Otkrivanje boja jedna je od prvih tehnika korištenja računalnog vida za detekciju požara, odnosno plamena i do danas je to daleko najpopularniji način detekcije koristeći RGB (RGB engl. Red green blue – Crveno, zeleno, plavo) model boja, ponekad u kombinaciji sa zasićenjem HSI (HSI engl. Hue, saturation, and intensity color space - Prostor boja temeljen na tonu, zasićenju i svjetlini) ili HSV (HSV engl. Hue, saturation, and value – Prostor boja temeljen na nijansi, zasićenosti i vrijednosti). Glavno pravilo tehnike otkrivanje odgovarajuće "vatre" je korištenje kolor piksela i to pomoću Gaussian-glačanim histogramom boja, statistički generiranim modelom boja i miješanjem funkcija.

Najpopularniji od svih formata u boji, RGB format opisuje svaki piksel koristeći tri osnovne boje i to crvenu, zelenu i plavu. Uz snažnu podršku ova metoda ima i nedostatke kao što su visoka osjetljivost na svjetlost i njenu promjenu, koja automatski djeluje na promjenu vrijednosti svih triju komponenata. U slučaju promjena osvjetljenja cijele okoline, ovaj nedostatak se može nadoknaditi kroz modifikaciju vrijednosti boja. Veći problem se javlja kada su određeni dijelovi promatranog prostora detekcije u sjeni, koja ima za posljedicu i vrlo zahtjevan računalni vid. Segmentacijom podataka boja slike u RGB formatu uspoređuju se vrijednosti svih triju osnovnih boja.

Slika 56 predstavlja RGB model prostora boja pomoću kocke. Crvena boja predstavlja x-os, zelena boja y-os, dok plava boja z-os. Boje su najčešće označene vrijednostima od 0 do 255 (256 vrijednosti). Ukupno je to  $256^3 = 16777216$  mogućih boja. Podaci raznih računalnih programa za obradu slike koriste podatak o 16 milijuna boja.



Slika 56: RGB model prostora boja

Izvor: [www.google.hr/search?q=RGB+color+space+model&biw](http://www.google.hr/search?q=RGB+color+space+model&biw)

HSI model opisuje prostor boja, isto kao i RGB model. Vrijednost piksela svake slike sastoji se od triju komponenata. Prvi je nijansa, zatim zasićenje i kao najnovija komponenta intenzitet. HSI format boja je mnogo otporniji na promjene svjetline ambijenta nego RGB model. HSI model segmentacije koristi samo nijansu i zasićenost komponente, dok informaciju vrijednosti intenziteta svjetlosti, ne koristi. HSI format je stoga posebno prikladan za upotrebu kod česte promjene osvjetljenja. Izračuni pretvorbe iz RGB u HSI format prikazani su jednadžbama, računalno se ponavljaju za svaki piksel slike [90] [91].

$$r = \frac{R}{R+G+B}, g = \frac{G}{R+G+B}, b = \frac{B}{R+G+B} \quad (4.3)$$

$$h = \cos^{-1} \left\{ \frac{0.5 \cdot [(r-g) + (r-b)]}{[(r-g)^2 + (r-b)(g-b)]^{1/2}} \right\} \quad h \in [0, \pi] \text{ for } b \leq g \quad (4.4)$$

$$h = 2\pi - \cos^{-1} \left\{ \frac{0.5 \cdot [(r-g) + (r-b)]}{[(r-g)^2 + (r-b)(g-b)]^{1/2}} \right\} \quad h \in [\pi, 2\pi] \text{ for } b > b \quad (4.5)$$

$$s = 1 - 3 \cdot \min(r, g, b) \quad s \in [0, 1] \quad (4.6)$$

$$i = (R + G + B) / (3 \cdot 255) \quad i \in [0, 1] . \quad (4.7)$$

gdje su:

$R$  = vrijednost crvene komponente

$G$  = vrijednost zelene komponente


$B$  = vrijednost plave komponente

$h$  = ton boje (engl. hue)

$s$  = komponenta zasićenja ( engl. saturation)

$i$  = intenzitet svjetlosti ( engl. intensity brightness)

Radi lakšeg snalaženja komponente  $h$ ,  $s$ , i  $i$  vrijednosti se pretvaraju u raspone od [0,360], [0.100], [0, 255], odnosno prema:  $H = h \times 180/\pi$  ;  $S = s \times 100$  i  $I = i \times 255$



Slika 57: HSI prostor boja

Izvor: [www.blackice.com/colorspaceHSI.htm](http://www.blackice.com/colorspaceHSI.htm)

HSI prostor boja je vrlo bitan model boja koji se koristi kao aplikacija za obradu slika, a sam model predstavlja boju na sličan način kao što ljudsko oko prepoznaje boje. Na slici su nijanse boja prikazane u obliku kutova od 0 – 360° i to: 0° – crvena boja, 120° – zelena boja, 240° – plava boja, 60° – žuta boja, 300° – magenta boja.

Boja plamena nije odraz prirodne svjetlosti, ali je generiran kao rezultat sagorijevanja materijala. U nekim slučajevima, boja može biti čak i bijela, plava, zlatna ili čak zelena ovisno o kemijskim svojstvima spaljena materijala i njegove temperature gorenja. Međutim, u slučajevima organskih materijala poput drva, vatra je poznato crveno-žute boje. Mnogi objekti su slične boje nastalog požara (uključujući Sunce, razna umjetna svjetla ili odrazi raznih površina) i često su pogrešno prepoznati kao plamen, kada odluka detekcije plamena uzima u obzir samo kriterij boja.

Iz tog razloga, postoje i dodatni kriteriji koji se koristiti za utvrđivanje razlike između lažnih alarmnih situacija i stvarne vatre. Korištenje prostorno-vremenskih kriterija plamena, algoritmi detekcije mogu značajno povećati računalnu složenost, zbog potrebe višedimenzionalne obrade slika. Ukoliko se koriste slike sivih tonova tada se uzimaju četiri dimenzije kontrole i to položaj, informacije piksela, osvjetljenje i vrijeme (x, y, Y, t) ili 6 dimenzija (x, y, R, G, B, t) u slučaju slike u boji koja ima crvene, zelene i plave komponente [91]. Većina napisanih radova u literature koristi čisto prostorni ili čisto vremenski kriterij, ili kombinirani pristup obaju prethodnih kriterija.

---

Boja **magenta** je osnovna komplementarna boja koja nastaje aditivnim miješanjem crvene i plave boje i ima u RGB-u vrijednost (255, 0, 255) decimalno ili FF00FF heksadecimalno.

#### 4.8.3. Upotreba računalnog vida za detekciju dima

Brz razvoj u računalnoj industriji u posljednja dva desetljeća omogućio je integraciju inteligentnih algoritama u softver sustava za videonadzor. Većina sustava nadzora već ima ugrađene jednostavne module za detekciju kao što je otkrivanje gibanja, analiza događaja.

U posljednjih nekoliko godina došlo je do značajnog interesa za razvoj algoritama za otkrivanje vatre i dima u realnom vremenu, koristeći standardne sustave nadzora. Većina komercijalno dostupnih detektora dima su detektori točkastog tipa. Ovi detektori se najčešće aktiviraju kada je perjanica dima blizu senzora. Stoga gotovo uvijek postoji kašnjenje aktiviranja detektora zbog njegovog smještajnog položaja. Videodetekcija dima može se koristiti upravo zato da bi se poboljšala situacija detekcije, budući da jedna kamera može nadzirati mnogo veće područje detekcije i to s udaljenosti, nego tradicionalni detektori dima koji uz to koriste vrlo robustan algoritam detekcije.

Detekcija dima temeljena na videu obećavajuća je alternativa tradicionalnim dimnim detektorima, no i ona ima neke nedostatke koje treba riješiti da bi sustav detekcije bio pouzdan. Dim je teško modelirati zbog njegove dinamične teksture i nepravilnih karakteristika pokreta. Nestabilne kamere uslijed vibracija, dinamičke pozadine, razne prepreke koje uvjetuju raspon gledanja kamera i raznovrsne rasvjete također predstavljaju neka od ograničenja kod problema detekcije dima. Većina algoritama za detekciju dima počiva na otkrivanju pokreta. Detekcija pokreta smanjuje područje traženja dima koji pak smanjuje troškove računalnih algoritama. Kvaliteta metode detekcija dima izravno ovisi o pouzdanosti algoritma detekcije pokreta. Mnogi algoritmi otkrivanja pokreta već rade dobro u praksi, međutim teži se razvijanju novih algoritama detekcije dima uzimajući u obzir dinamičke pozadine.

Jedan od primjera algoritma detekcije dima u svom radu pod nazivom *Detekcija dima na videu u svrhu sustava ranog alarmiranja u slučaju vatre (The Smoke Detection for Early Fire-Alarm System Based on Video)* opisali su Thou-Ho (Chao-Ho) Chen, Yen-Hui Yin, Shi-Feng Huang and Yan-Ting Ye s Nacionalnog sveučilišta primijenjenih znanosti iz Tajvana [92]. U radu je prikazan postupak otkrivanja dima u ranoj fazi požara temeljeno na obradi videa.

Proučavajući dim, zaključili su da je u mnogim slučajevima dim sive boje koja zavisi o temperaturi dima i fazi izgaranja. U slučaju niske temperatura dima, raspon boja je moguć od bijelo-plave do bijele, a ukoliko je temperatura visoka, boja dima može biti od sivo-crne

do crne. Međutim, problem se javlja kada pojedini objekti, na slici odgovaraju bojama dima, što otežava pravilnu detekcije dima. Takav problem postoji u dva slučaja i to kada objekti koji nisu dim imaju slične boje, ili ako pozadinsko osvjetljenje emitira boje slične bojama dima. Zbog toga su oni uzeli u obzir i dinamička svojstva dima, odnosno detekciju su vršili na pokretnoj slici. Njihova strategija algoritma otkrivanja dima sastoji se od dviju funkcija odlučivanja i to na temelju statičkih karakteristika i dinamičkog obilježja. Kod statičke analize sive boje se mogu prikazati kao nijanse tamno sive i svijetlo sive. Koristeći karakteristike boje dima pomoću RGB modela boja, objasnili su karakteristiku dima izrazom:

$$A \pm \alpha = G \pm \beta = B \pm \gamma. \quad (4.8)$$

Kako su znali da se siva boja može predstaviti I (intenzitet) komponentom koristili su HSI model boja predstavljajući intenzitet svijetlih i tamno sivih boja pomoću:

$$L_1 \leq I \leq L_2$$

$$D_1 \leq I \leq D_2.$$

Kako su  $L_1$ ,  $L_2$ ,  $D_1$  i  $D_2$  granične vrijednosti uz pomoć eksperimenata došli su do zaključka da su njihove zadovoljavajuće vrijednosti

$$15 \leq \alpha \leq 20$$

$$D_1 = 80, D_2 = 150$$

$$L^1 = 150, L^2 = 220.$$

Kod dinamičke analize pretpostavili su da se uslijed različitih strujanja javljaju i nepredvidiva kretanja dima što je otežavalo samu analizu dima zbog čega su koristili pravilo:

$$\text{If} \left( \frac{SEP}{STP} \right) \geq STD$$

*Then Smoke*

*Else Not Smoke ,*

gdje su:


$SEP$  = suma opsega segmentiranih područja dima

$STP$  = broj piksela koji su detektirani kao dim

$STD$  = eksperimentalno određena granična vrijednost.

Uz navedene karakteristike vršili su dinamičku provjeru brzine povećanja površine dima na slici pomoću broja piksela i vremenskog trenutka.

Eksperimentalni rezultati njihovog rada pokazali su da predloženi algoritam (Slika 63), odnosno metoda otkrivanja dima može povećati rani alarm uz nižu stopu lažnih alarma prije nego se razvije požar. Sličnu metodu detekcije dima u svom radu pod nazivom *Detekcija dima na videu u svrhu sustava ranog alarmiranja* (*Smoke Detection for Early Fire-Alerting System Based on Video Processing*), opisali su autori Da-Jinn Wang, Ti-Ho (Chao-Ho) Chen, Yen-Hui Yin i Tsong-Yi Chen [93].



Slika 58: Algoritam detekcije dima na videu u svrhu sustava ranog alarmiranja


Izvor : <http://ieeexplore.ieee.org/>



## 5. PRIJEDLOG MODELA BRODSKOGA VATRODOJAVNOG SUSTAVA TEMELJENOG NA RAČUNALNOM VIDU

### 5.1. Primjena računalnog vida za detekciju rane faze nastanka požara na brodu

Danas su brodske strojarnice zaštićene od požara s automatskim sustavom za gašenje, koji se kontrolira u prostoru smještenom izvan strojarnice. Da bi sustav gašenja vodenom maglom mogao startati, moraju se aktivirati dva različita detektora od kojih je jedan detektor plamena kojemu ne smetaju razna strujanja prouzročena ventilacijom ili propuhom i vrlo brzo se aktivira i dimni detektor kojemu ta strujanja smetaju uslijed čega kasni njegova aktivacija, a samim tim i aktivacija automatskog gašenja, uslijed čega dolazi do rasplamsavanja požara i njegovog prijenosa na okolne prostore. Ovaj rad opisuje provedena istraživanja primjene već postojećih brodskih CCTV sustava u ranom otkrivanju dima u strojarnici, što bi bio doprinos bržem suzbijanju neželjenih posljedica.

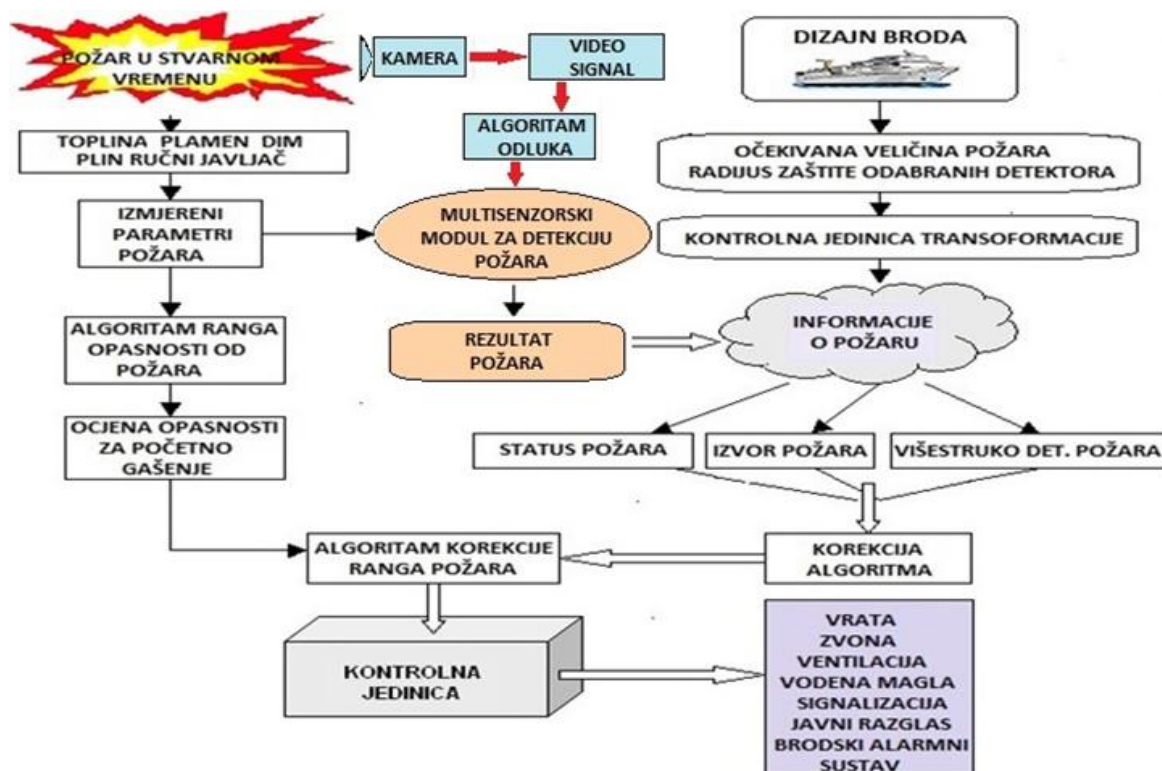


Slika 59: Usporedba područja detekcije klasičnih detektora i videotehnologije upotrebom računalnog vida

Tradicionalna metoda detekcije dima zahtijeva potrebu postavljanja detektora u blizini samog izvora dima. Kako bi se izbjegao taj nedostatak postavljena je teza korištenja metode detekcije dima bazirane na videu u svrhu poboljšanja uspješnosti otkrivanja dima i smanjenja lažnih detekcija. Prema statistikama broj smrtnih slučajeva uzrokovanih dimom iznosi 50%-80 % od ukupnog broja stradalih u požaru, što znači da je dim glavni uzrok smrtnosti. Na

brodu uvijek ima raznih gorivih otpada, a pogotovo u brodskoj strojarnici, koja u procesu izgaranja proizvode velike količine otrovnih plinova i ujedno troše velike količine kisika.

Na temelju karakteristika dima i plamena, proučavajući razne klasične koncepte algoritama za detekciju plamena i dima te distribuciju izlaznih signala, a na osnovi istraživanja, predlaže se sustav brodske vatrodajave klasičnog koncepta algoritma unaprijeđen VID sustavom koristeći već instalirani brodski CCTV sustav, slika 60.



Slika 60: Koncept klasičnog modela algoritma požara, distribucije izlaznih signala i VID sustava

## 5.2. Prijedlog modela detekcije dima temeljenog na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera

Kao sigurnosne aplikacije videokamere imaju široku upotrebu posebno u području detekcije požara s obzirom da je vatra vodeća opasnost koja utječe na svakodnevni život. U vezi s tim kao nova platforma videoobrade sekvenci u otkrivanju i analizi požara ili dima,

odnosno mogućeg otkrivanja požara i dima, tehniku računalnog vida, može se suplementirati u već postojeći videosustav.

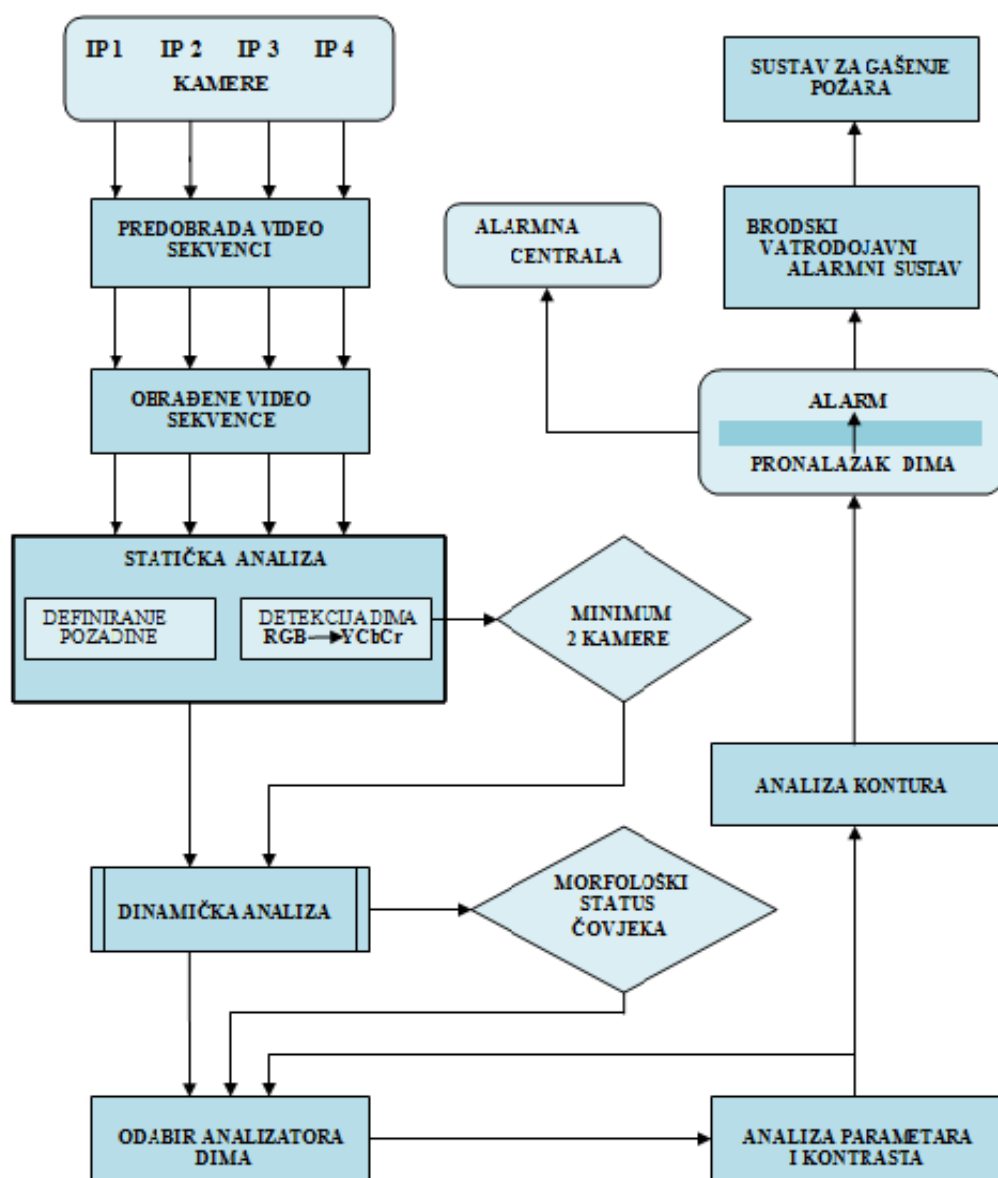
Konvencionalni detektori uglavnom su ograničeni svojim položajem u prostoru, odnosno reagiraju samo u blizini plamena i dima te često ne mogu na vrijeme pružiti odgovarajuću informaciju o mjestu požarnog incidenta i dimenziji razmjera požara uslijed kašnjenja signala. Upravo zato VID sustav pruža ogromni potencijal za uspješno otkrivanje plamena ili dima u vrlo kratkom vremenu.

U prethodnim poglavljima prikazane su i objašnjene mnoge nove elektroničke i računalne tehnologije i tehnike korištene u vatrodojavnim sustavima, također i koncept klasičnog modela algoritma detekcije požara i distribucije izlaznih signala bez i s upotrebom VID sustava, nudeći rješenja za što učinkovitiji rad vatrodojavnog sustava u pružanju sigurnosti korisnicima sustava.

Znajući da je preko 95 % znanstvenih istraživanja o upotrebi videotehnologije u ranom otkrivanju vatre, odnosno dima i plamena korišteno za uporabu na kopnu i to u početku za otkrivanje šumskih požara, a zatim i velikim prostorima kao što su sportske arene i razna skladišta materijala, ovaj rad bavi se korištenjem slične tehnologije za primjenu detekcije dima u brodskoj strojarnici određenog tipa broda.

Za potrebe istraživanja u sklopu ovoga rada zamišljen je model broetskog vatrodojavnog sustava koji koristi postojeći brodski CCTV sustav s četiri IP (internet protokol) kamere smještene u prostoru glavnog pogonskog stroja. Vizualni detektori požara, odnosno IP kamere su montirane i smještene na projektno određenim pozicijama, sa zadatkom nadzora mogućih požarnih incidenata koji mogu uzrokovati dim, na primjer u strojarnici broda, prikupljajući *real-time* videosnimke te pomoću softvera analizirajući promjene u boji, uzorke pokreta i niz drugih parametara koji ukazuju isključivo na ponašanje dima. Predloženi modela zasniva se samo na detekciji dima u realnom vremenu, a ne i na detekciji plamena. Razlog izostavljanja detekcije plamena je u već postojećim detektorima plamena. Treba naglasiti da detektori plamena nisu osjetljivi na razna strujanja zraka, kao što je ventilacija strojarnice, propuh uslijed otvaranja vrata, već plamen direktno aktivira senzor, a ne kao detektor dima gdje medij kao što je dim treba doći u doticaj direktno sa senzorom detektora. Detekcija plamena je vrlo brza, što je još jedan razlog zašto se u radu ne poklanja dovoljno pažnje videodetekciji plamena. Vrste vatrodojavnih detektora plamena i njihov rad opisana su u poglavlju dva.

Predloženi model detekcije dima uporabom računalnog vida u realnom vremenu ima tri ključne karakteristike. Obradu videosekvenci uz statičku analizu temeljenu na RGB modelu boja; dinamičku analizu temeljenu na pokretu dima uz uvjet da minimalno dvije kamere istovremeno prepoznaju dim kao dostatan znak da dim doista postoji; analizu parametara, kontura i kontrasta, nakon čega slijedi alarm i njegova daljnja distribucija, vidljivo iz slike 61.



Slika 61: Model detekcije dima temeljen na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera

---

### 5.3. Opis modela za detekciju dima temeljenog na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera

Požar u većini slučajeva počinje s emisijom dima, a tek onda slijedi plamen. Stoga je prisutnost dima jako bitan faktor u otkrivanju žarišta požara. Općenito raspon boja dima je od bijele do bijelo - plavkaste kada je temperatura izgaranja niska i siva do crna kada temperatura izgaranja raste do temperature zapaljenja. Kamere koje se koriste su IP (internet protokol) CCD kamere visoke rezolucije s 420 TV linija (oko 380.000 piksela). Kao osnovni element gotovo svih današnjih kamera je CCD senzor (CCD = Charge Coupled Device). CCD senzor kao vrlo fotoosjetljivi element sastoji se od fine mreže individualnih piksela (mikrotočkica na elementu). Promatranu sliku pomoću IP kamere fokusira se kroz objektiv na površinu elementa i generirajući električni signal proporcionalan intenzitetu svjetla koji na njega pada. Tako se stvara električna forma slike koja pada na element. Broj piksela za CCD elemente prosječno iznose između 250.000 i 500.000 piksela.

#### 5.3.1. Predobrada videozapisa DCT transformacijom

Da bi se IP kamerama snimljene videosekvence mogle koristiti, potrebna je njihova predobrada kao preduvjet statičke analize. Zadatak predobrade videozapisa, odnosno pretprocesiranja je olakšavanje daljnje analize. Prednost korištenja IP tehnologije za detekciju požara naspram jedinstvenog sustava videonadzora je u njezinoj preciznosti. Za predloženi model odabrana je predobrada videozapisa na osnovi DCT (Diskretna kosinusna transformacija) transformacije, odnosno tehnika komprimiranja podataka prilikom obrade slika [103], [104], [106]. Diskretna kosinusna transformacija je tehnika pretvaranja signala u osnovne komponente frekvencije.

Transformacija se ne vrši na cijelim slikama, već se slike rastavljaju na blokove veličine 8 X 8. Pripremanje slike za JPEG koder počinje premještanjem slike iz RGB u YCbCr sustav boja, gdje je Y komponenta osvijetljenosti, a Cb i Cr komponente obojanosti slike. Pomoću JPEG dekodera nakon što se završi DCT proces pristupa se invertnim koracima kako bi se vratila originalna slika za daljnju analizu. Slika je dvodimenzionalni prikaz u ravnini (dvije dimenzije), odnosno ona je funkcija intenziteta svjetlosti u dvodimenzionalnom području (2D). Jednadžba za dvodimenzionalnu DCT transformaciju glasi [107]:

$$F(u, v) = C(u)C(v) \sum_{x=0}^{N-1} \sum_{y=0}^{N-1} f(x, y) \cos \frac{\pi(2x+1)u}{2N} \cos \frac{\pi(2y+1)v}{2N} . \quad (5.1)$$

Za invertnu IDCT transformaciju ona je:

$$f(u, v) = \sum_{u=0}^{N-1} \sum_{v=0}^{N-1} C(u)C(v) F(u, v) \cos \frac{\pi(2x+1)u}{2N} \cos \frac{\pi(2y+1)v}{2N} , \quad (5.2)$$

gdje su:

$F(u, v)$  = koordinate DCT koeficijenata

$N$  i  $N$  = horizontale i vertikalne (stupci i redovi)

$C(u)$  i  $C(v)$  = skup rezultata, koji se određuje prema vrijednosti koeficijenta  $u$  i  $v$

$f(x, y)$  = vrijednost piksela matrice u točki  $(x, y)$

$\pi$  = vrijednost  $180^\circ$ .


U fazi detekcije prostora strojarnice, koristeći DC svakog DCT bloka od  $8 \times 8$  koeficijenata, nakon nekoliko uzastopnih okvirnih sekvenci, pokreta i snimljenih svojstava boja analizom se utvrđuje postoji li mogući dim čime su obrađene sekvence spremne za statičku analizu.



Slika 62: Kompresija ulazne slike na  $8 \times 8$  blokova

### 5.3.2. Statička analiza videozapisa

Boja kao vrlo važna značajka često se koristi u raznim algoritmima otkrivanja dima koristeći RGB model boja. Prvo pravila na kojem se temelji detekcija dima je činjenica da je dim sive boje, što znači da je intenzitet triju osnovnih boja jednak. Drugo pravilo određuje da je intenzitet sive boje negdje između 80 i 220 područja, gdje 0 predstavlja crnu boju, a 255 bijelu boju (Slika 63). Raspon područja sive boje ukazuje da dim nije niti bijel niti tako crn.



Slika 63: Boje RGB modela koje se detektiraju kao dim

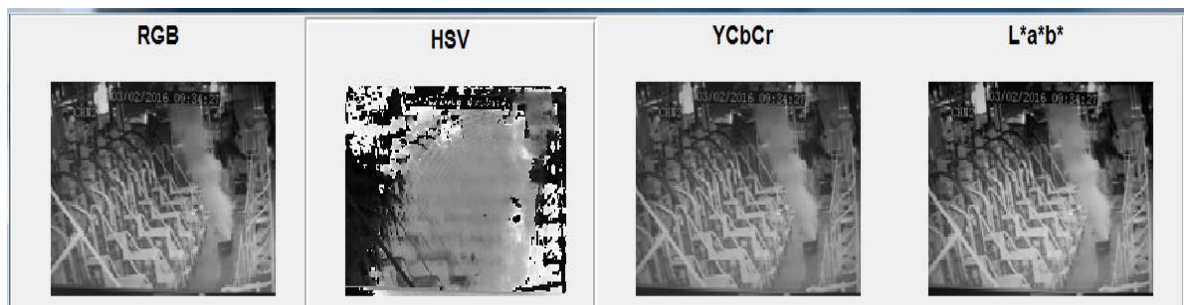
Isto tako prema prethodno navedenim autorima u poglavlju 4.9., za svaku nijansu sive boje, s lijeva na desno, vrijednosti crvene, zelene i plave komponente su jednake.

Na osnovi navedenih pravila (opisanih u prethodnom poglavlju), predložene su jednadžbe:

$$\text{Pravilo 1} \quad R \pm \alpha = G \pm \alpha = B \pm \alpha \quad (5.1)$$

$$\text{Pravilo 2} \quad 80 \leq \frac{R+G+B}{3} \leq 220 . \quad (5.2)$$

Ukoliko su oba navedena pravila zadovoljena tada algoritam pretpostavlja da je dim stvaran. Međutim kako bi statička analiza dima bila što djelotvornija [103] potrebno je videosekvence snimljene IP kamerama u formatu MJPEG prebaciti iz RGB sustava u YCbCr sustav. HSV sustav boja nije se pokazao adekvatan kod statičke analize, vidljivo iz slike 74.



Slika 64: Prikazivanje slike modelima boja pomoću programa MATLAB

Iz toga slijedi i prilagodba jednadžba [109]:

$$\text{Pravilo 1} \quad (C_b^{DC}(x, y) - 128)^2 + (C_r^{DC}(x, y) - 128)^2 \leq \alpha^2 \quad (5.3)$$

$$\text{Pravilo 2} \quad Th_3 \leq Y^{DC}(x, y) \leq Th_4, \quad (5.4)$$

gdje su:

$Y^{DC}(x, y), C_b^{DC}(x, y), C_r^{DC}(x, y)$  = DC vrijednosti dvaju signala boje i osvjetljenje kanala  $(x, y)$  th bloka, a primjenom linearne transformacije između RGB i YCbCr.

Iz vidljivog slijedi da je  $\hat{\alpha} = 10, Th3 = 80$  i  $Th4 = 220$ .

Ukoliko su oba pravila zadovoljena tada  $(x, y)$ -th blok smatra da je boja dima stvarna. Iz toga proizlazi da je:

$$f_c = (Y^{DC}(x, y), C_b^{DC}(x, y), C_r^{DC}(x, y)) = 1, \quad (5.5)$$

$$\text{inače bi bilo} \quad f_c = (Y^{DC}(x, y), C_b^{DC}(x, y), C_r^{DC}(x, y)) = 0. \quad (5.6)$$

Na osnovi analize videozapisa potvrđujući postojanje područje zahvaćeno dimom slijedi da je:

$$B_t(x, y) = f_m(Y_{t-1}^{DC}(x, y), Y_t^{DC}(x, y)) \wedge f_c(Y^{DC}(x, y), C_b^{DC}(x, y), C_r^{DC}(x, y)). \quad (5.7)$$



Gdje operater " $\wedge$ " označava logično-a. Ako je binarna matrica  $Bt(x, y)$  jednako 1, onda je  $(x, y)$  th blok kandidat kao dimni blok, jer u slučaju da nije, blok se odbacuje. Da bi se pristupilo dinamičkoj analizi videozapisa osim definiranja pozadine u ovome predloženom modelu uvjet je da minimum dvije kamere istovremeno potvrde prisutnost dima u određenom brodskom prostoru.

Definiranje pozadine u statičkoj analizi usmjerena je na usporedbu promatrane slike (strojarnica) u video sekvenci sa slikom koja ne sadrži bilo koji predmet interesa, odnosno sustav dijeli promatranu sliku u dvama komplementarnim setovima piksela, gdje prvi set sadrži objekte od interesa, a drugi u pozadini njegov komplementarni set. Za definiranje pozadine najčešće se koristi Gaussov model smjese boje.

### 5.3.3. Dinamička analiza videozapisa

Karakteristike dima na kojima se temelji dinamička analiza su nepravilnost, difuzija i smjer kretanja. Prostor brodske strojarnice podložen je raznim strujanjima zraka uslijed rada ventilacijskog sustava ili propuha. Strujanja djeluju na kretanje dima i njegovu konturu. Uz problem strujanja javlja se i problem sjene, prisutnosti ljudi i njihovi pokreti. Da bi dinamička analiza bila što uspješnija jako je bitno pozadinsko oduzimanje, odnosno područje posebnog interesa (ROI) uspoređuje se s pozadinskom slikom (Slika 65).



Slika 65: Usporedba pozadinske slike i područja interesa ROI

Smjer kretanja dima uvijek je od dna prema vrhu. U otkrivanju dima koristi se smjer vektora pomaka kao parametar. Ako je smjer gibanja kao što smo rekli od dolje prema gore,

odnosno od mjesta nastanka dima prema plafonu, cilj smatra da je dim stvaran. Upravo zato se i koristi dinamička karakteristika dima da bi ga se otkrilo. Kako bi se izbjegli lažni alarmi koje prouzrokuju dijelovi područja i predmeti sličnih boji dima, postavlja se prag vrijednosti pomoću kojeg se utvrđuje je li dim stvaran ili nije, a pravilo glasi [110]:

*Ako je omjer boje  $\geq$  od definiranog praga, tada bi dim mogao biti stvaran. U suprotnome ne.*

Difuzija kao dinamička značajka također služi za izračun stope rasta, odnosno opsega dima, pomoću kojeg se utvrđuje je li dim stvaran ili nije. S obzirom na proces difuzije plinova, područje dima u slijedu slika stalno se povećava. Ako je stopa rasta konture dima veća od određenog praga tada se može vjerovati da je dim stvaran ili možda ne, a pravilo glasi:

*Ako je stopa rasta  $\geq$  od definiranog praga, tada bi dim mogao biti stvaran. U suprotnome ne.*

Uslijed širenja i povećavanja veličine dima (opseg dima), stopa rasta se računa koristeći jednadžbu:

$$\Delta A_{di} = \frac{dA}{dt} = \frac{A_{i+k} - A_i}{(i+k) - i} , \quad (5.8)$$

gdje su:

$A_i$  = dimno područje u jedinici vremena

$i$  = okvir slijeda slika

$k$  = broj sličica između dviju odabranih ulaznih slika

$(i + k) - i$  = broj okvira.

Za izračun srednje vrijednosti stope rasta dima koristi se jednadžba:

$$\overline{\Delta A_{di}} = \frac{1}{n} \sum_{i=1}^n \Delta A_{di} , \quad (5.9)$$

Zbog utjecaja različitih strujanja i mijenjanja oblika dima, radi točnosti srednju vrijednost se provjerava više puta.

$$\text{If Broj}(D_1 < \overline{\Delta A_{di}} < D_2) > N_d \quad H_d = (D_1 < \overline{\Delta A_{di}} < D_2) \quad (5.10)$$

$$\text{If Broj } H_d > N_d$$

*Jeste dim*

*Ili nije dim ,*

gdje su:

$D_1$  i  $D_2$  = granične vrijednosti donje i gornje brzine povećavanja dima

$H_d$  = granična vrijednost broja zadovoljavanja uvjeta ( $D_1 < \overline{\Delta A_{di}} < D_2$ ),

Obradom videosekvenci intervali područja obuhvaćenog dimom pomoću metode vremena, može se zamijeniti intervalom boja pomoću jednadžbe:

$$\Delta A_{di} = \frac{dP}{dt} = \frac{P_{i+k} - P_i}{(i+k)-i}, \quad (5.11)$$

gdje su:

$P_i$  = ukupan broj piksela dima u zahvaćenom prostoru

$i$  = okvir slijeda slika

$k$  = broj slika između dviju odabranih ulaznih slika

$(i + k) - i$  = broj okvira.

Dinamičkom analizom pogrešne blokove videodetekcije dima treba izolirati. Tu spada i morfološki status čovjeka. Uzimajući u obzir ekspanziju dima kao karakteristiku dima, izolirani blokovi se smatraju pogrešnim blokovima. Eliminacija izoliranih blokova vrši se pomoću binarne matrice  $B_t$  opisane u poglavlju 5.4.2.



Slika 66: Detektirani dim na prikazanoj slici

#### **5.3.4. Odabir videoanalizatora dima i podešavanje parametara**

Predloženi model broškog vatrodojavnog sustava bazira se na upotrebi postojećih CCTV sistema. Model detekcije dima temeljenog na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera za čitanje i analizu videosekvenci u AVI formatu, koristi AVI player. Program za detekciju može biti instaliran u samom CCTV sustavu ili na nekom od brodskih računala. Da bi detekcija dima, odnosno aplikacija uredno započela rad i bila što djelotvornija, potrebno je odabrati vrstu video analizatora dima pogodnog za prostore kao što je brodska strojarnica. Nakon odabira videoanalizatora potrebno je podesiti odgovarajuće parametre i pristupiti analizi sustava radi li zadovoljavajuće ili ne. Ukoliko sustav ne radi kako treba proces treba ponoviti sve dok ne utvrdimo je li u redu. Podešeni parametri su u funkciji procjene događaja, odnosno raspoznavanja dima.

---

## 6. EVALUACIJA USPJEŠNOSTI PREDLOŽENOG MODELA BRODSKOG VATRODOJAVNOGA SUSTAVA TEMELJENOG NA RAČUNALNOM VIDU

Princip rada vizualne kontrole dima kao novog alata u vrlo ranoj detekciji plamena ili dima, temelji se na sofisticiranoj računalnoj analizi i obradi videoslike, tj. područja pokrivenog CCTV IP kamerama. Koristeći najnovija dostignuća u videotehnologiji upotrebom CCTV sustava i pripadajućih IP kamera u detekciji dima i plamena, istraživanjem primijenila se implementacija takve tehnologiju u brodskoj strojarnici, odnosno testiranjem predloženog modela u realnim brodskim uvjetima i na osnovi testiranja doneseni su određeni zaključci.

### 6.1 Uvodna razmatranja

Da bi se dokazala djelotvornost detekcija dima temeljena na računalnom vidu izvodili su se eksperimenti detekcije upotrebom klasičnih detektora dima i naprednog sustava detekcije koristeći IP kamere. Procjena odgovora klasičnog detektora dima temelji se na optičkoj gustoći, porastu temperature, alarmnom pragu, brzini i smjeru širenja. Operativni brodski sustav ventilacije strojarnice smanjuje optičku gustoću dima uslijed dotoka svježeg zraka, što znači da je optička gustoća koja prouzrokuje alarm značajno veća, nego kada djeluje brodski ventilacijski sustav strojarnice. Na detekciju dima temeljenu na računalnom vidu ovaj parametar nema utjecaja.

Predloženi model detekcije dima temeljen na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera ima za cilj razvoj i automatizaciju videosustava ranog upozorenja, odnosno detekcije dima integrirajući postojeći brodski klasični sustav vatrodojave i videosustav u jednu naprednu cjelinu. Prikupljeni podaci i mjerenja distribuirani u centralnu jedinicu CCTV sustava uz pomoć inteligentnog računalnog vida i algoritma prepoznavanja se automatski analiziraju, a zatim pomoću programa generiraju određeni signali upozorenja, odnosno alarm za otkrivanje dima. Predloženi model detekcije pruža informacije u realnom vremenu. Komponente i funkcionalnost predloženog modela dizajnom zadovoljavaju određene uvjete, kao što su:

- programska podrška

- 
- arhitektura predloženog modela
  - zahtjev za brzinom detekcije
  - procjena i vizualizacija širenja dima
  - ekonomska i pravna ograničenja
  - funkcionalnost i dr.

Sporo vrijeme odziva klasičnih točkastih detektora navelo je znanstvenike da se kao alternativa umjesto klasičnih detektora ponudi zamjenski volumetrijski sustav detekcije temeljen na računalnom vidu.

Vrijeme kao glavni čimbenik na kojem se temelji predloženi napredni model detekcije, automatski proporcionalno utječe i na smanjenje moguće štete. Istovremeno smanjenjem vremena odziva uvelike se povećava šansa za pravovremeno gašenje požara. Postojeći brodske sustavi videonadzora u načelu uz nisku cijenu koštanja, lako se mogu nadograditi pružajući uz postojeći videonadzor istovremeno i automatsku videodetekciju plamena ili dima.

## **6.2 Odabir i definiranje početnih uvjeta analiziranih scenarija detekcije rane faze u nastanku požara upotrebom optičkog detektora dima**

Kao mjesto ispitivanja klasičnog modela vatrodajave i predloženog modela izabrana je brodska strojarnica kao specifičan prostor gdje se u prosjeku najčešće događaju požarni incidenti. Prostor strojarnice širok je otprilike 10 metara, dužine 16 metara i visine od mjesta simulacije dima do stropa oko 8 metara.


Uvjeti ispitivanja adekvatni su realnim uvjetima broda u eksploataciji, a to su:

- uključena sva rasvjetna mjesta brodske strojarnice napajana naizmjeničnim naponom 220 V s glavne rasklopne ploče (28 neonskih lampi snage 64W, ukupno 896 W)
- jedan pomoćni dizelski motor u radu priključen na glavnu rasklopnu ploču
- uključen kompresor zraka
- sustav goriva u funkciji
- rashladni sustavi i sustavi podmazivanja pogona u radu
- alarmni sustav vatrodajave u funkciji

- glavni stroj spreman za pogon
- zatvorena sva vrata i izlazi u nuždi
- ventilacija strojarnice:
  - scenarij 1 – ventilacija strojarnice isključena
  - scenarij 2 – u funkciji sva ventilacija brodske strojarnice uz dotok dovoljne količine svježeg zraka za nesmetani rad cjelokupnog pogona. Količina dotoka svježeg zraka je  $19,1 \text{ m}^3/\text{s}$ ., odnosno  $68500 \text{ m}^3/\text{h}$ , gustoće  $1,13 \text{ kg/m}^3$  pri temperaturi brodske strojarnice od  $+35 \text{ }^\circ\text{C}$ .

### 6.2.1. Ispitivanje detekcije dima klasičnim optičkim detektorima dima

Detektori dima korišteni u testu su tip *Salwico* EV-P analogno adresabilni detektori s optičkim komorama nominalnog napona 24 VDC, radne struje 0,2 mA, struja alarma 5 mA, i raspona od  $-25 \text{ }^\circ\text{C}$  do  $+70 \text{ }^\circ\text{C}$ . Smještaj detektora prikazan je na sljedećoj slici. Ispitivanja su se izvodila u dva scenarija.




Slika 67: Scenarij 1– detekcija dima bez uključene ventilacije strojarnice

Izvor: Izradio autor na temelju nacrtu Uljanikove novogradnje 722

Tablica 13: Vrijeme alarma optičkih detektora dima bez uključene ventilacije strojarnice

DETEKTOR DIMA	POČETAK DIMA	ALARM
07037	00 min. 00 sek.	01 min. 15 sek.
07038	00 min. 00 sek.	01 min. 46 sek.
07039	00 min. 00 sek.	01 min. 26 sek.
07040	00 min. 00 sek.	01 min. 10 sek.




Slika 68: Scenarij 2 – detekcija dima s uključenom ventilacijom strojarnice

Izvor: Izradio autor na temelju nacрта Uljanikove novogradnje 722

Tablica 14: Vrijeme alarma optičkih detektora dima s uključenom ventilacijom strojarnice

DETEKTOR DIMA	POČETAK DIMA	ALARM
07037	00 min. 00 sek.	02 min. 56 sek.
07038	00 min. 00 sek.	04 min. 10 sek.
07039	00 min. 00 sek.	04 min. 50 sek.
07040	00 min. 00 sek.	02 min. 33 sek.






Grafikon 10 : Usporedba vremena alarma detekcije dima s (scenarij 1) i bez uključene ventilacije strojarnice (scenarij 2)

Tablica 15: Vrijeme detekcije dima – test scenarij 1 i scenarij 2 – razlika u brzini detekcije

DETEKTOR DIMA	Vrijeme detekcije dima bez ventilacije t1	Vrijeme detekcije dima sa ventilacijom t2	Razlika u brzini vremena detekcije dima $\Delta t$
07037	01 min. 15 sek.	02 min. 56 sek.	01 min. 41 sek.
07038	01 min. 46 sek.	04 min. 10 sek.	02 min. 24 sek.
07039	01 min. 26 sek.	04 min. 50 sek.	03 min. 24 sek.
07040	01 min. 10 sek.	02 min. 33 sek.	01 min. 23 sek.

### 6.2.2. Ispitivanje detekcije dima upotrebom VID sustava i IP kamera

Da bi se pristupilo ispitivanju predloženog modela pomoću videosustav nadzora ELRO DVR74S, s četiri videokanala, montirane su četiri vanjske IP kamere na za to predviđenim mjestima prikazanim kao na slici 69.



Slika 69: Pozicije IP kamera za test videodetekcije dima

Video sustav ELRO DVR74S s 4 kamere (Slika 70), može istovremeno prikazivati 4 slike na zaslonu od 7 inča i dodatnom zaslonu kao što je zaslon broetskog računala. Ugrađeni snimač na tvrdom disku omogućuje zapisivanje slika na tvrdi disk kapaciteta 500 GB. Horizontalna rezolucija je 450 TV linija uz element slike 628 X 586. Videozapis je u AVI formatu.



Slika 70: Videosustav nadzora ELRO DVR74S

Program koji se koristio tijekom ispitivanja videodetekcije dima sličan je programu koji se koristi za nadzor i otkrivanje šumskih požara, gdje je polučio zadovoljavajuće rezultate.

### 6.3 Ispitivanje i ocjena uspješnosti predloženog modela

Reprezentativan videotest snimljen je pomoću IP kamere smještenih na četiri lokacije. Lokacija pričvršćenja kamere 2 je prema pramčanom dijelu dolje okrenuta prema glavnom stroju, dok je kamera 1 ispod stropa pramčanog dijela strojarnice okrenute prema dolje. Istovremeno kamera 3 smještena je ispod stropa krmenog dijela strojarnice okrenuto prema dolje, a kamera 4 na krmenom dijelu dolje, okrenuta je prema glavnom stroju vidljivo iz tablice 16. Vrijeme korištenih videodatoteka je otprilike 60 minuta. Test se izvorno snimao u komprimiranom AVI videoformatu.

Tablica 16: Orijentacija kamera za pojedinačni test

TEST	VIDEO DATOTEKA	LOKACIJA KAMERE	
		POZICIJA	SMJER
KAMERA 1	ch1-092442	GORE	KRMA
KAMERA 2	ch2-091939	DOLJE	KRMA
KAMERA 3	ch3-091933	GORE	PRAMAC
KAMERA 4	ch4-092342	DOLJE	PRAMAC

Kao gorivi materijal koristila se smjesa teškog goriva glavnog stroja, dizelsko gorivo pomoćnih motora i guma. Programske postavke za videodetekciju dima mijenjale su se s obzirom na izbor tipa detektora. Kao tipovi detektora moglo se birati kao video detektor dima korišten za detekciju dima u šumama, klasičan video dimni detektor i Markov video-dimni detektor. Testiranjem kao najbolji video dimni detektor pokazao se videodetektor dima korišten za detekciju dima u šumama, jer pruža mogućnosti bitnih postavki uvjetovanih prostorom brodske strojarnice:

- eliminacija pokretne pozadine
- zaštita u slučaju vibracija
- podešavanje svjetlosti dima s obzirom na pozadinu
- analiza sjena i korištenje SVM klasifikacije
- određivanje veličine blokova uzoraka
- podešavanje osjetljivosti i rezolucije videosekvence.

Brzina detekcije pojedine kamere s obzirom na smještaj i videoanalizu prezentirana je slikom 72 i tablicom 17.



Slika 71: Videodetekcija dima pomoću 4 kamere u razmaku od 3 sekunde



### KAMERA 1



### KAMERA 2



### KAMERA 3



### KAMERA 4



Slika 72: Videoslike od nastanka dima do alarma

Tablica 17: Vrijeme detekcije dima upotrebom računalnog vida i IP kamera od nastanka dima do alarma

## TEST 1


	POČETAK DIMA	ALARM
KAMERA 1	00,00 sek.	02,04 sek.
KAMERA 2	00,00 sek.	02,02 sek.
KAMERA 3	00,00 sek.	05,28 sek.
KAMERA 4	00,00 sek.	03,30 sek.

## TEST 2

	POČETAK DIMA	ALARM
KAMERA 1	00,00 sek.	02,22 sek.
KAMERA 2	00,00 sek.	02,58 sek.
KAMERA 3	00,00 sek.	03,05 sek.
KAMERA 4	00,00 sek.	01,14 sek.

## TEST 3

	POČETAK DIMA	ALARM
KAMERA 1	00,00 sek.	01,55 sek.
KAMERA 2	00,00 sek.	02,29 sek.
KAMERA 3	00,00 sek.	03,53 sek.
KAMERA 4	00,00 sek.	02,34 sek.



Grafikon 11: Vremena alarma detekcije dima upotrebom kamera triju različitih testova

Tablica 18: Vrijednosti vremena detekcije dima upotrebom IP kamera

	Vrijeme do alarma test 1 t1	Vrijeme do alarma test 2 t1	Vrijeme do alarma test 3 t3	Srednje vrijeme do alarma t
KAMERA 1	02,04 sek.	02,22 sek.	01,55 sek.	01,936 sek.
KAMERA 2	02,02 sek.	02,58 sek.	02,29 sek.	02,297 sek.
KAMERA 3	05,28 sek.	03,05 sek.	03,53 sek.	03,953 sek.
KAMERA 4	03,31 sek.	01,14 sek.	02,34 sek.	02,263 sek.


Iz prezentiranih podataka jasno je vidljivo da je predloženi brodski model videodetekcije vrlo funkcionalan. Uvjet modela da minimalno dvije kamere istovremeno aktiviraju alarm je ispunjen.

#### 6.4 Komparativna analiza klasičnog i novog predloženog pristupa u detekciji rane faze nastanka požara


Analizirajući rad predloženog modela videodetekcije dima na osnovi rezultata testa došlo se do spoznaje o prednosti korištenja automatskog sustava detekcije dima na temelju videotehnologije:

- odziv videodetekcije dima mnogo je brži od klasičnog vatrodojavnog sustava
- sustav radi veoma dobro u prostorima visokog stropa i velikih površina


- strujanja zraka ne utječu na videodetekciju
- promjena temperature i vlage nema utjecaja na detekciju
- snimljene fotografije ili videoisjecci omogućavaju pronalazak uzročnika i mjesta nastanka požarnog incidenta
- na osnovi snimaka moguća je i procjena štete
- vrlo lako se može ukomponirati u postojeći brodski vatrodajavni sustav.



Grafikon 12: Usporedba vremena aktivacije optičkih detektora dima bez uključene ventilacije i videodetekcije dima upotrebom IP kamera



Grafikon 13: Usporedba vremena aktivacije optičkih detektora dima s uključenom ventilacijom i videodetekcije dima upotrebom IP kamera



Grafikon 14: Vremena detekcije dima upotrebom optičkih detektora i VID tehnologije

Tablica 19 : Usporedba srednjih vremenskih vrijednosti detekcije dima upotrebom optičkih detektora dima i detekcije dima zasnovane na upotrebi računalnog vida (IP kamere)

	<b>Det.1</b> 070377	<b>Det. 2</b> 07038	<b>Det.3</b> 07039	<b>Det. 4</b> 07040	<b>Kamera</b> 1	<b>Kamera</b> 2	<b>Kamera</b> 3	<b>Kamera</b> 4
$t_{AB}$	02 min00sek	02min00sek	02min00sek	02min00sek	02min0,0sek	02min0,0sek	02min0,0sek	02min0,0sek
$t_{BC}$	02min56sek	04min10sek	04min50sek	02min33sek	00min4,0sek	00min2,0sek	00min5,3sek	00min3,3sek
$t_{AC}$	04min56sek	06min10sek	06min50sek	04min33sek	02min4,0sek	02min2,0sek	02min6,0sek	02min3,3sek

$t_{AB}$  = vrijeme potrebno za pripreme dimljenja

$t_{BC}$  = vrijeme detekcije dima

$t_{AC}$  = ukupno vrijeme do alarma dima

$\Delta t_{det}$  = srednje vrijeme detekcije dima upotrebom klasičnih optičkih detektora

$\Delta t_{det} = 217,25$  sekundi

$\Delta t_{kam}$  = srednje vrijeme detekcije dima upotrebom video tehnologije (IP kamera)

$\Delta t_{kam} = 3,65$  sekundi

$\Delta t_v$  = razlika u brzini detekcije

$$\Delta t_v = \frac{\Delta t_{det}}{\Delta t_{kam}} = 59,52.$$

Usporedbom vrijednosti navedenih u tablici 19 može se zaključiti da je vrijeme detekcije dima videotehnologijom mnogo brže za razliku od detekcije korištenjem klasičnih adresno analognih optičkih detektora dima. Uzimajući u obzir srednje vrijeme detekcije



-----

korištenjem optičkih detektora dima i srednje vrijeme upotrebom kamera, zaključak je da je brzina odziva videotehnologije 59,52 puta brža od klasičnih optičkih detektora dima.

Nedostaci predloženog modela sustava videodetekcije dima na temelju video tehnologije su:

- videosustav zahtijeva minimalne uvjete osvjetljenja za nadzirano područje detekcije
- videokamere moraju biti u skladu minimalne tehničke izvedbe
- javlja se problem vibracija koje mogu utjecati na kvalitetu snimki
- svaka kamera zahtijeva parametre ovisno o mjestu postavljanja i u okruženju
- potrebno je čistiti zaštitno staklo, u protivnom kvaliteta snimke može biti loša i tako utjecati na detekciju
- sustav još uvijek nema dozvolu za brodsku upotrebu.

Brzina detektiranja dima videotehnologijom i aktivacija alarma u prosjeku se dešava za otprilike oko 2 – 3 sekunde, dok kod klasičnog javljača ovisi o površini kontrole, visini prostora i raznim strujanjima zraka koja utječu na smjer dima.

#### **6.5 Analiza ekonomske opravdanosti predloženog modela u funkciji smanjenja ukupnih troškova uzrokovanih nepravovremenom detekcijom rane faze nastanka požara u brodskoj strojarnici**

Vatra je jedan od prva tri uzroka gubitka plovila i jedan od glavnih rizika za Ro-Ro trajekte i putničke brodove. Pravovremena informacija o mjestu požarnog incidenta najvažnija je u njegovom suzbijanju ili bar ograničavanju daljnjeg širenja. Sam rizik od požara nikada ne može biti do kraja eliminiran, ali se njegovi učinci mogu uvelike ublažiti.

Brzinu širenja požarnog incidenta nemoguće je predvidjeti. Nekada se plamen ili dim u strojarnici toliko brzo proširi da sustav automatskog gašenja ne stigne reagirati na vrijeme i nastala šteta je enormna, dok nasuprot imamo slučajeve kada su dostatni i obični ručni aparati za gašenje i šteta je neznatna. Da bi se prikazala ekonomska opravdanost predloženog modela u funkciji povećanja sigurnosti na brodu i smanjenja mogućih nastalih troškova potrebno je znati i cijenu pojedinog sustava strojarnice (Tablica 20).

Tablica 20: Cijene sustava i pojedinačnih uređaja brodske strojarnice za tri tipa broda sagrađenih u brodogradilištu *Uljanik*

SUSTAVI I UREĐAJI BRODSKE STROJARNICE	BROD ZA PRIJEVOZ RASUTOG TERETA	BROD ZA PRIJEVOZ NAFTE	BROD ZA PRIJEVOZ AUTOMOBILA
1- INCENERATOR	48.807,00 USD	48.807,00 USD	48.807,00 USD
2-SANITARNA VODA	26.606,00 USD	26.606,00 USD	26.606,00 USD
3-UREĐAJ ZA TRETIRANJE FEKALIJA	25.400,00 USD	25.400,00 USD	25.400,00 USD
4-GLAVNI MOTOR	3.381.000,00 USD	3.500.000,00 USD	3.600.000,00 USD
5-KOMPRESORI	32.000,00 USD	32.000,00 USD	35.000,00 USD
6-PITKA VODA	23.500,00 USD	23.500,00 USD	23.500,00 USD
7-POMOĆNI MOTORI	757.000,00 USD	800.000,00 USD	900.000,00 USD
8-SEPARATORI	118.000,00 USD	118.000,00 USD	118.000,00 USD
9-JEDINICA ZA PRIPREMU GORIVA	80.000,00 USD	80.000,00 USD	80.000,00 USD
10-PUMPE	83.000,00 USD	83.000,00 USD	93.000,00 USD
11-RASHLADNICI	34.000,00 USD	34.000,00 USD	40.000,00 USD
12-POPATNA OPREMA	50.000,00 USD	50.000,00 USD	57.000,00 USD
<b>UKUPNO</b>	<b>4.659.313,00 USD</b>	<b>4.821.313,00 USD</b>	<b>5.047.313,00 USD</b>

Prethodna tablica prikazuje cijenu koštanja važnih brodskih sustava strojarnice za tri tipa broda izgrađenih u brodogradilištu *Uljanik*. Iz tablice se može iščitati koliki ukupni financijski gubitak može prouzročiti kasno uočavanje i nepravovremena reakcija suzbijanja požarnog incidenta. U ukupni gubitak nisu uračunati i popratni radovi poput bojanja, varenja, montaže cjevovoda i ostalih radova u funkciji ispravne brodske strojarnice spremne za pogon.

Tablica 21: Cijene broškoga vatrodojavnog sustava i CCTV sustava za tri tipa broda

	BROD ZA PRIJEVOZ RASUTOG TERETA	BROD ZA PRIJEVOZ NAFTE	BROD ZA PRIJEVOZ AUTOMOBILA
VATRODOJAVNA CENTRALA	20.500,00 USD	24.500,00 USD	82.000,00 USD
CCTV SUSTAV	6.400,00 USD	6.400,00 USD	12.000,00 USD

Kada se usporede cijene brodskih vatrodojavnih sustava (Tablica 21) prezentiranih tipova brodova sa ukupnom cijenom strojeva i uređaja pojedinog tipa brodske strojarnice, zaključak je da bi se ulaganje u predloženi model broškoga vatrodojavnog sustava temeljenog na računalnom vidu, s povećanjem cijene vatrodojavnog sustava za 20 %, ekonomski vrlo brzo isplatilo. Treba imati na umu da brodovi novijeg datuma već posjeduju instalirane CCTV sustave te se implementacijom programa videodetekcije dima u postojeći CCTV sustav, vrlo brzo predloženi model može staviti u funkciju cjelokupnog vatrodojavnog sustava.

## ZAKLJUČAK

Cilj ove doktorske disertacije bio je procijeniti učinkovitost upotrebe komercijalno dostupnog CCTV videosustava u detekciji dima na brodu, točnije u brodskoj strojarnici. Određen je cilj kao i svrha istraživanja, a to je povećanje učinkovitosti brodskog vatrodojavnog sustava primjenom novih elektroničkih i računalnih tehnologija, točnije upotreba videotehnologije u detekciji dima. Primarni cilj je bio utvrditi razumijevanje osjetljivosti performansi i ograničenja koja mogu utjecati na videodetekciju dima, upotrebom različito postavljenih kamera uz realne uvjete u brodskoj strojarnici.

Hipoteza disertacije postavljena je u uvodnom dijelu, a to je tvrdnja da se primjenom novih elektroničkih i računalnih tehnologija i tehnika u svrhu unaprjeđenja brodskog vatrodojavnog sustava, povećava efikasnost automatske detekcije požara, uz povećanje stupnja raspoloživosti i sigurnosti sustava brodske vatrodojave, te zaštite broda od požara. Uz glavnu hipotezu disertacije definirane su i pomoćne hipoteze, uz potvrdu njihove ispravnosti.

Prva pomoćna hipoteza, a to je pouzdanost alarmnog sustava vatrodojave, objašnjena je povećanjem sigurnosti detekcije ranog otkrivanja požarnog incidenta (dima) upotrebom IP kamera instaliranog CCTV sustava sa sigurnim i uspješnim radom predloženog modela kroz besprijekorno funkcioniranje i bez kvara cjelokupnog sustava.

Druga i treća pomoćna hipoteza – unaprjeđenje karakteristike brodskog vatrodojavnog sustava, s aspekta povećanja brzine detekcije rane faze nastanka požara uz istodobno smanjenje broja detektiranih lažnih alarma, opisane su u poglavlju 5. Uspoređujući brzinu detekcije dima pomoću klasičnih dimnih detektora i detekcije dima upotrebom videotehnologije u prostoru brodske strojarnice došlo se do zaključka da brzina otkrivanja dima videodetekcijom pruža daleko bržu mogućnost intervencije gašenja u samom začetku požarnog incidenta. Uz brzinu detekcije, postiglo se i smanjenje stope lažnih alarma. Konvencionalni detektori podložni su nečistoći, vlazi, raznim strujanjima zraka, što uvelike pospješuje broj lažnih alarma, dok kod kamera smještenih u kućišta toga nema, pod uvjetom pravilnog održavanja.

Četvrta pomoćna hipoteza istraživanja pod naslovom smanjenje troškova izazvanih požarom, uz povećavanje zaštite ljudskog života od moguće pogibelji, kao i zaštite broda u cjelini opisana je i potvrđena u petom poglavlju analizom i usporedbom cijena brodskih alarmnih vatrodojavnih sustava, brodskog sustava videonadzora i sustava instaliranih u

-----

brodskoj strojarnici za tri različita broda sagrađena u brodogradilištu *Uljanik*. Zaključak analize je da se minimalnim ulaganjima u postojeće vatrodojavne sustave, uz bržu i pravovremenu detekciju, doprinosi većoj sigurnosti, očuvanju funkcionalnosti vitalnih uređaja i sustava strojarnice potrebne za pogon broda, spašavanju samog broda, broorskog tereta, spašavanju života, što donosi sveobuhvatnu financijsku korist za vlasnika broda.

Tijekom testa sustav je bio izložen nizu potencijalnih smetnji kao mogućih izvora lažnih alarma. Ispitivanje je provedeno s aktivnom pozadinom uz prisutnost ljudi koji su sudjelovali u pripremi i tijeku ispitivanja, a u skladu s uvjetima osvjetljenja brodske strojarnice tijekom navigacije. Ispitivanje je izvedeno pomoću četiri kamere usmjerene prema istom vidnom polju. Nakon izvedenog ispitivanja prišlo se pojedinačnoj usporedbi videozapisa za svaku IP videokameru.

Dobiveni rezultati predloženog modela pokazali su iznimnu učinkovitost. Također, rezultati testa pokazali su da pravilnim odabirom odgovarajućih parametara, učinak dima, boje pozadine, brodske rasvjete i kretanje ljudi nemaju većeg značaja za osjetljivost videodetekcije dima. Nadalje, postigao se cilj modela da minimalno dvije kamere odnosno analizom videosekvenci se potvrdi istovremena signalizacija dima, kao uvjet sigurnog raspoznavanja stvarnog dima od lažnog.

Zna se da je prvih pet minuta ključno za razvoj požara, a nakon sedam do deset minuta požar se toliko raširi uz ekstremno visoku temperaturu te postaje uzrokom velikih oštećenja brodske opreme, a često i gubitka broda. Upravo zbog takvih činjenica videosnimke se mogu koristiti za analizu rizika i prevenciju budućih brodskih požarnih incidenata. Uz ključne funkcionalnosti kao što su brzina detekcije dima i vizualna provjera, predloženi model detekcije dima ima još neke prednosti nad klasičnim brodskim vatrodojavnim sustavom. Tu se prvenstveno misli na pouzdano i vrlo rano upozorenje na prisutnosti dima, sigurna i daljinska provjera mjesta nastanka alarma, laka integracija s postojećim sustavom vatrodojave i nizak trošak održavanja. Međutim, uz prednosti koje pruža videodetekciju dima ili plamena, sustav još uvijek nije odobren za korištenje na novogradnjama iz razloga nedovoljnog testiranja na brodovima u realnim eksploatacijskim uvjetima. Na brodu su uz visoke temperature u strojarnici, prisutne i velike vibracije koje mogu stvarati probleme kamerama i samoj detekciji.

Analiza predloženog modela i njegova efikasnost u realnim uvjetima prisutnim u brodskoj strojarnici uz implementaciju videosustava za nadzor u vatrodojavni sustav,

-----

potvrđena je primjena predloženog modela detekcije dima koristeći računalni vid pri obradi slika niskih kvaliteta.

Uzimajući u obzir činjenice navedene u disertaciji znanstveni doprinos doktorata ogleda se u sljedećem:

- predloženi model detekcije dima upotrebom video tehnologije i računalnog vida, testiranjem je dokazao da se primjenom novih elektroničkih i računalnih tehnologija, povećava pouzdanost, raspoloživost i sigurnost broorskog vatrodojavnog sustava
- predloženim modelom smanjio se i broj detektiranih lažnih alarma
- u praktičnom smislu model pridonosi mogućnost praktične primjene na brodu
- model je dobar temelj za daljnja unaprjeđenja i poboljšanja broorskih alarmnih vatrodojavnih sustava.

Predloženi model detekcije dima mogao bi potaknuti nova tehnička rješenja vezana uz broorske vatrodojavne sustave za postizanje cilja trajne primjene detekcije dima uporabom videotehnologije.

Daljnja istraživanja upotrebe videotehnologije u detekciji dima na brodu, doprinijet će poboljšanju učinkovitosti detekcije dima i svrsishodnost implementacije sustava video nadzora u broorski vatrodojavni sustav. Budućnost alarmnih vatrodojavnih broorskih sustava uz integraciju centralnog broorskog vatrodojavnog sustava i videosustava je i upotreba termovizije u detekciji vatre i dima, čime bi se kao jedna cjelina unaprijedili broorski alarmni sustavi vatrodojave.

## LITERATURA

## Popis literature:

- [1] Tubbs, J. S.; Intelligent Fire Alarm Systems, Fire Protection Engineering Journal by the Society of Fire Protection Engineer SFPE, Issue No. 11, OH, USA, September 2011.
- [2] Hadžiefendić, N.; Detekcija požara, Elektrotehnički fakultet, Beograd, Novembar, 2006.
- [3] Fire Dynamics Tools (FDTs), Quantitative Fire Hazard Analysis Methods for the U.S. Nuclear Regulatory Commission Fire Protection Inspection Program [Draft] November, 2004.  
[http://www.nfpa805.com/Fire\\_Modeling/Fire\\_Modeling\\_Information.htm](http://www.nfpa805.com/Fire_Modeling/Fire_Modeling_Information.htm)
- [4] Kezić, D.; Efikasnost vatrodojavnih sustava na brodu, Zbornik radova, 36 simpozij Elmar, Hrvatska, Zadar, 1994.
- [5] Howard, E.; Thermostatic Bimetal, Engineering and Science, p. 16–24.  
<http://resolver.caltech.edu/CaltechES:5.4.Howard>
- [6] Budnick, E.K., Evans, D.D., Nelson, H.E.; Simple Fire Growth Calculations, Section 11 Chapter 10, NFPA Fire Protection Handbook, 18th Edition, National Fire Protection Association, Quincy, Massachusetts, 1997.
- [7] [Online], <http://www.nfpa.org/>
- [8] Geiman, J. A.; Evaluation of Smoke Detector Response Estimation Methods, Master of Science, 2003. <http://drum.lib.umd.edu/bitstream/handle/1903/113/dissertation.pdf>
- [9] Milked, J.; The History of Smoke Detection, University of Maryland, 2010.  
<http://www.enfp.umd.edu/faculty/milke>
- [10] Ahrens, M.; Fire Analysis and Research Division National Fire Protection Association, Quincy, 2007. [www.nfpa.org/~mediaFiles/Research/OSHomes.ashx](http://www.nfpa.org/~mediaFiles/Research/OSHomes.ashx)
- [11] [Online], <http://www.todayifoundout.com/index.php/2012/04/how-a-smoke-alarm-works/>
- [12] [Online], [http://en.wikipedia.org/wiki/Smoke\\_detector](http://en.wikipedia.org/wiki/Smoke_detector)
- [13] Hadžiefendić, N.; Fire Alarm, Electrical Engineering, Belgrade, 2006.
- [14] Prpić, E., Vuković, B., Dončević, R., Kauzlarić, D.; Introduction to System Design Tip Fire Alarm Automatic Door, Rijeka, 2010.

- 
- [15] Draganović, M.; Zaštita u slučaju požara, FER, Zagreb, 2012.
- [16] Maksimović, M.; Optimalno raspoređivanje senzora za detekciju dima i toplote, Elektrotehnički fakultet, INFOTEH–JAHORINA Vol. 13, March, 2014.
- [17] [Online], <http://www.vatrodajava.hr/grupa-12/Analogno-adresabilni-detektori-po%9Eara-INIM.php>
- [18] Lozica, M., Drakulić, M.; Modern Fire Detection Systems in Road Tunnels“, The Scientific Expert Conference „Security in the environment and jobs, Solaris, May, 2002.
- [19] Liu, Z., Ferrier, G., Bao, X., Zeng, X. et al. Brillouin Scattering Based Distributed Fiber Optic Temperature Sensing for Fire Detection, Fire Safety Science 7, University of Ottawa, 2003. p. 221–232.
- [20] Zhang, L., Wang, G.; Design and Implementation of Automatic Fire Alarm System Based on Wireless Sensor Networks, International Symposium on Information Processing ISIP’09 Huangshan, PR China, August, 2009. p. 410–413.
- [21] [Online], [http://www.occush.vtsnis.edu.rs/aktivnost\\_8/tribina\\_Nis\\_februar\\_mart\\_2013/prilog\\_8\\_tribina\\_nis\\_2013.pdf](http://www.occush.vtsnis.edu.rs/aktivnost_8/tribina_Nis_februar_mart_2013/prilog_8_tribina_nis_2013.pdf)
- [22] Nyssönen, T., Rajakko, J., Rahkonen, Č.; On the Reliability of Fire Detection and Alarm Systems, ESPOO 2005. <http://www.vtt.fi/inf/pdf>
- [23] SOLAS Appendix 5: Resolution MSC.216– Annex 3, adopted on 8 December 2006.
- [24] [Online], [www.fpz.unizg.hr/zto/AUTOM/9autom-sigurnost.pdf](http://www.fpz.unizg.hr/zto/AUTOM/9autom-sigurnost.pdf)
- [25] [Online], <http://www.etf.ucg.ac.me/materijal/1273603779sk1112.pdf>
- [26] [Online], [www.iacs.org.uk](http://www.iacs.org.uk)
- [27] Guidelines for Measures to Prevent Fires in Engine–Rooms and Cargo Pump–Rooms, IMO Msc.1/circ 1321, London 2009.
- [28] Charchalis, A., Czy, S.; Analysis of Fire Hazard and Safety Requirements of a Sea Vessel Engine Rooms, Gdynia Maritime University, Faculty of Marine Engineering, Journal of KONES Powertrain and Transport, Vol. 18, No. 2 2011.
- [29] Measures to prevent fire in engine–rooms and cargo pump–rooms, IMO FP 52/WP.6, London, 2008.
- [30] Pavelić, Đ.; Mjere zaštite od požara, Sigurnost 54 (2), Zagreb, 2012. Str. 205–208
- [31] [Online], <https://prekucavanje.files.wordpress.com/2012/10/uzroci-pozara.pdf>

- 
- [32] Bengtsson, L.G.; Enclosure Fires, Per Hardestam and others, 2001.  
<http://www.ctif.org/library-item/enclosure-fires>
- [33] [Online], <https://www.google.hr/#q=iskre+mehani%C4%8Dkog+porijekla>
- [34] Gottuk, D. T., Peatross, M.J.; Class B Firefighting Doctrine and Tactics: Final Report, Naval Research Laboratory, Washington DC, 1996.
- [35] Karlsson, B., Quintere, J.; Enclosure Fire Dynamics, Institutionen för brandteknik, Lunds Universitet, Lund 1997
- [36] [Online], <http://pbadupws.nrc.gov/docs/ML0432/ML043290075.pdf>
- [37] Janssens, M.; Computer Tools to Determine Material Properties for Fire Growth Modelling from Cone Calorimeter Data, Southwest Research Institute, San Antonio, TX, USA.
- [38] Ingason, H.; Design Fires in Tunnels, ASIAFLAM '95, Kowloon, Hong Kong, 1995.
- [39] Thomson, H., Drysdale, D.; Flammability of Plastics I: Ignition Temperatures, Fire and Materials, vol. 11, 1987. p. 163–172
- [40] [Online], <http://www.nfpa.org/codes-and-standards/document-information-pages?mode=code&code=30>
- [41] Hurley, M.J., Bukowski, R.W.; Fire Hazard Analysis Techniques, 3–134 SECTION 3 Information and Analysis for Fire Protection,  
<http://fire.nist.gov/bfrlpubs/fire08/PDF/f08005.pdf>
- [42] Tewarson, A.; Generation of Heat and Chemical Compounds in Fires, SFPE Handbook of Fire Protection Engineering, 3rd ed., P. J. DiNenno et al. (Eds.), National Fire Protection Association, Quincy, MA, 2002.
- [43] Schifiliti, R. P., Meacham, B. J., and Custer, R. L. P.; Design of Detection Systems, SFPE Handbook of Fire Protection Engineering, National Fire Protection Association, Quincy, MA, 2002.
- [44] Engineering Guide–Human Behavior in Fire, Society of Fire Protection Engineers, Bethesda, MD, 2003.
- [45] Cengel, Y. A.; „Introduction to Thermodynamics and Heat Transfer“, Second Edition, 2008.  
[http://www.academia.edu/4517673/Cengel\\_Thermodynamics\\_Heat\\_Transfer\\_2nd\\_txtbk](http://www.academia.edu/4517673/Cengel_Thermodynamics_Heat_Transfer_2nd_txtbk)
- [46] [Online], <http://webserver.dmt.upm.es/~isidoro/bk3/c11/Heat%20conduction.pdf>



- [47] Ventura, M.; Safety of Life at Sea, 1974 SOLAS, MSc in Marine Engineering and Naval Architecture.
- [48] Shangchun Z.; Fire Protection on Board: enhance fire safety by design, World Maritime University, 2000.
- [49] MARITIME SAFETY COMMITTEE 87th session, MSC 87/26 25 May 2010.
- [50] SOLAS Appendix 5: Resolution MSC.216– Annex 3, adopted on 8 December 2006.
- [51] Mirjana, M.; Fuzzy Logic Usage in WSN for Fire Detection, Infoteh Jahorina Vol. 13, 2014.
- [52] Lindsay, S. M.; Introduction to Nanoscience, Oxford University Press, New York, USA, 2010.
- [53] Mitin, V., Kochelap V., Strosio M.; Introduction to Nanoelectronics (Science, Nanotechnology, Engineering and Applications), Cambridge University Press, Cambridge UK, 2008.
- [54] Liu, Z., Ferrier, G., Bao, X., Zeng, X. et al; Brillouin Scattering Based Distributed Fiber Optic Temperature Sensing for Fire Detection, Fire Safety Science 7, University of Ottawa, 2003. p. 221–232.
- [55] Lozica, M., Drakulić, M.; Modern Fire Detection Systems in Road Tunnels, The Scientific Expert Conference Security in the environment and jobs, Solaris, May, 2002.
- [56] Grattan, K. T. V., Meggitt, B.T.; Optical Fiber Sensor Technology, Chapman and Hal, London, 1998.
- [57] [Online], <http://www.capgo.com/Resources/Temperature/FibreOptic/Fibre.html>
- [58] Rose-Pehrsson, S. L., Minor, C. P., Johnson, K. J., Owrutsky, K. J. et al; The Multi-sensory, Data Fusion Detection System for Improved Situational Awareness, ECS Transactions, U.S. Naval Research Lab SW Washington, 2008.
- [59] Gottuk, D. T.; Video Image Detection Systems Instalation, Hughes Associates.
- [60] Lawrence, S., Chiu, M.; Study on the Video Smoke Detection System, International Journal on Engineering Performance-Based Fire Codes, Volume 6, Number 4, 2004. p. 258–263.
- [61] Celik, T., Demirel, H., Ozkaramanli, H.; Fire Detection Using Statistical Color Model in Video Sequences, Journal of Visual Communication and Ima Representation, Volume 18, Issue 2, 2007. p. 176–185.

- 
- [62] Lawrence, S., Chiu, M.; Study on the Video Smoke Detection System, International Journal on Engineering Performance-Based Fire Codes, Volume 6, Number 4, 2004. p. 258–263.
- [63] Brovko, N., Bogush, R., Ablameyko, S.; Smoke Detection Algorithm for Intelligent Video Surveillance System, Computer Science Journal of Moldova, vol. 21, no.1 2013.
- [64] Bolourchi, P., Uysal, S.; Forest Fire Detection in Wireless Sensor Network Using Fuzzy Logic, Fifth International Conference on Computational Intelligence Communication Systems and Networks, 2013.
- [65] Mohindru, P., Singh, R.; Multi-Sensor Based Forest Fire Detection System, International Journal of Soft Computing and Engineering IJSCE, Volume-3, Issue-1, 2013.
- [66] Mohindru, P., Khanna, V., Singh, R.; Forest Fire Detection: Various Approaches, International Journal of Emerging Science and Engineering IJESE, Volume-1, Issue-6, 2013.
- [67] Hakkarainen, T., Hietaniemi, J., Hostikka, S., Karhula, T., et al; Survivability for Ships in Case of Fire. SURSHIP-FIRE project, Espoo. VTT Tiedotteita-Research Notes 2497, 2009.
- [68] Vikshant, K., Rupinder K. C.; Fire Detection Mechanism Using Fuzzy Logic, International Journal of Computer Applications Volume 65-No.12, 2013.
- [69] Petrović, K.; Infracrvena Termografija, Mjerna i regulacijska tehnika, Kem. Ind. 65 (1-2), Zagreb, 2016. p. 110–113.
- [70] Pašagić, V., Mužević, M., Kelenc, D.; Infrared Thermography in Marine Applications, Brodarski Institut, Brodogradnja **59**, Zagreb, Croatia, 2008. p. 123–130.
- [71] Gaussorugues, G., Chomet, S.; Infrared Thermography, Kluwer Academic Pub, 1994.
- [72] FLIR, Infrared Camera Used for Inspection of Ships:  
[www.industrysearch.com.au/Features/FLIR\\_Infrared\\_Camera\\_Used\\_for\\_inspection\\_of\\_Ships](http://www.industrysearch.com.au/Features/FLIR_Infrared_Camera_Used_for_inspection_of_Ships)
- [73] FLIR Systems; ThermoCAMTM P65 User's manual, 2005.
- [74] Radmilović, Ž., Kolar-Gregorić, T.; „Kriminalističko istraživanje požara“, Polici.sigur., broj 1, Zagreb, 2010. str. 50–66.
- [75] Pačelat, R., Zorić, Z.; Istraživanje uzoraka požara, Zavod za istraživanje i razvoj sigurnosti, Zagreb, 2003.

- 
- [76] Šnajder, J., Dalbelo–Bašić, B.; Uvod u umjetnu inteligenciju, Fakultet elektrotehnike i računarstva, Sveučilište u Zagrebu Ak.god. 2014/2015.
- [77] Engelbrecht, A. P.; Computational Intelligence, An Introduction, Second Edition, University of Pretoria, South Africa, 2007.
- [78] Bugarić, M.; Prepoznavanje dima i vatre temeljeno na analizi digitalne slike, Fakultet elektrotehnike, strojarstva i brodogradnje, Sveučilište u Splitu, prosinac, 2007.
- [79] Chen, T.H., Kao, C.L., Chang, S.M.; An Intelligent Real–Time Fire Detection Method Based on Video Processing, Security Technology, Proceedings. IEEE 37th Annual International Carnahan Conference on 14–16, Oct, 2003. p. 104–111.
- [80] Toreyin, B. U., Dedeoğlu, Y., Gudukbay, U., Cetin, A. E.; Computer Vision Based System for Real–time Fire and Flame Detection, Pattern Recognition Letters, 2006. p. 49–58.
- [81] Toreyin, B. U., Dedeoğlu, Y., Gudukbay, U., Cetin, A. E.; Wavelet Based Real–Time Smoke Detection in Video, 13th European Signal Processing Conference EUSIPCO, Antalya, 2005.
- [82] Chen, T. H., Yin, Y. H., Huang, S.F., Ye, Y. T.; The Smoke Detection for Early Fire–Alarming System Base on Video Processing, Intelligent Information Hiding and Multimedia Signal Processing IIH–MSP '06. International Conference, 2006. p. 427–430.
- [83] Dedeoğlu, Y., Toreyin, B. U., Gudukbay, U., Cetin, A. E.; Real–time Fire and Flame Detection in Video, IEEE 30th International Conference on Acoustics, Speech and Signal Processing, ICASSP'05, Philadelphia, USA, 2005.
- [84] Celik, T., Ma, K. K.; Computer Vision Based Fire Detection in Color Images, Proceedings of the IEEE Conference on Soft Computing on Industrial Applications SMCia, June, 2008. p. 258–263.
- [85] Marbach, G., Loepfe, M., Brupbacher, T.; An Image Processing Technique for Fire Detection in Video Images, Fire Safety Journal, vol. 41, no. 4, 2006. p. 285–289.
- [86] Celik, T., Ozkaramanli, H., Demirel, H.; Fire Pixel Classification Using Fuzzy Logic and Statistical Color Model, Acoustics, IEEE International Conference, Volume 1, April, 2007. p. I–1205– I–1208
- [87] Chen, Y. L., Chin, T. L., Chao, T. H., Miin, T. S.; Smoke Detection Using Spatial and Temporal Analyses, International Journal of Innovative Computing, Information and Control, Volume 8, Number 7(A), July, 2012. p. 4749–4770

- 
- [88] Kaurić, I., Šipić, G.; Klasifikacija piksela na temelju svojstava boja RGB modela u sustavima za automatsku detekciju dima, Fakultet elektrotehnike i računarstva, Zagreb, Siječanj 2011.
- [89] Yong, X., Xingjie, Z., Binglei, X.; Method Design of Small-scale Fire Detection, Journal of Computational Information Systems 8: 17, 2012. p. 7355–7365.
- [90] Jian, F. L.; A New Equation of Saturation in RGB-to-HSI Conversion for More Rapidity of Computing, Machine Learning and Cybernetics, Proceedings, International conference, Vol.3, 2002. p. 1493–1497.
- [91] [Online], <http://www.cse.usf.edu/~mshreve/rgb-to-hsi>
- [92] Chen, T. H., Yin, Y. H., Huang, S. F., Ye, Y. T.; The Smoke Detection for Early Fire–Alarming System Base on Video Processing, National Kaohsiung University of Applied Sciences, Taiwan, Dec. 2006.
- [93] Wang, D. J., Chen, T. H., Yin, Y. H., Chen, T. Y.; Smoke Detection for Early Fire–Alarming System Based on Video Processing, Proceedings of the International Conference on Intelligent Information Hiding and Multimedia, IEEE Computer Society, Washington DC, USA, 2006. p. 427–430.
- [94] Petelin, S., Perković, M., Vidmar, P., Petelin, K.; „Ship’s Engine Room Fire Modelling, International Joint Power Generation Conference, Atlanta, Georgia, USA, 16–19 June, 2003.
- [95] Jones, W. W., Forney, G. P., Peacock, R. D., Reneke, P. A.; A Technical Reference for CFAST: An Engineering Tool for Estimating Fire and Smoke Transport, National Institute of Standards and Technology, NIST TN 1431, USA 2000.
- [96] Peacock, R. D., Jones W. W., Bukowski R. W.; Verification of a Model of Fire and Smoke Transport, Fire Safety Journal, Vol.21, 1993. p. 89–129.
- [97] There is Smoke Without Fire, Maritime IT & Electronics, IMAREST, Jan/Feb 2003. p. 6–8.
- [98] Wang, L., Su, S.; Simulation of Smoke Motion in Fire of the Ship Engine Room with Multilayer Structure, Brodogradnja, Vol.62 No.4, Prosinac 2011. p. 366–372.
- [99] Wang, L., Su, S., Nie, Y.; Modeling and Characteristic Analysis of the Flashover of Fire in a Ship Engine Room, Proceedings of the International Symposium on Safety Science and Technology, Hangzhou, China, 2010. p. 610–615.
- [100] McGrattan, K., Hostikka, S. et al.; Fire Dynamics Simulator Technical Reference Guide, National Institute of Standards and Technology, U.S. Department of Commerce, 2008.

- [101] Poinso, T., Veynante, D.; Theoretical and Numerical Combustion, Philadelphia, R.T. Edwards, Inc., 2005.
- [102] Bistrović, M., Tomas, V.; Application of New Techniques and Information Technology for Early Fire Detection on Ships, Our Sea, International Journal of Maritime Science & Technology, Vol.61 No.5–6, December, 2014.
- [103] Leonardo Millan-Garcia, Gabriel Sanchez-Perez, Mariko Nakano, Karina Toscano-Medina, Hector Perez-Meanam, Luis Rojas-Cardenas., An Early Fire Detection Algorithm Using IP Cameras, National Polytechnic Institute, San Francisco Culhuacan, Mexico, May, 2012.
- [104] Töreyn, B. U., Dedeoğlu, Y., and Çetin, A. E. 2005. Flame detection in video using hidden Markov models. *In* Proceedings of the IEEE International Conference on Image Processing, Genoa, Italy, 11–14 September, 2005.
- [105] Xu. Z.; Xu, J. Automatic Fire Smoke Detection Based on Image Visual Features. Proceedings of International Conference on Computational Intelligence and Security Workshops, Heilongjiang, China, 15–19 December, 2007.
- [106] B. U. Toreyin, A. E. Cetin, Real-time Fire and Smoke Detection in Video, Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing, Philadelphia, PA, USA, 18-23 Mart, 2005.
- [107] [Online], <http://spvp.zesoi.fer.hr/seminari/2000/kompresije/dct/dct.htm>
- [108] Chen, T.; Yin, S; Huang, Y.; Ye, Y.; The Smoke Detection for Early Fire–Alarming System Based on Video Processing. Proceedings of International Conference on Intelligent Information Hiding and Multimedia Signal Processing, Pasadena, CA, USA, 18–20 December, 2006.
- [109] Davis, B. J; Nawab, S. H.; The Relationship of Transform Coefficients for Differing Transform and/or Differing Subblock Sizes. IEEE Trans. *Signal*. Process. 2004. p. 1458–1461.
- [110] Töreyn, U. B., Dedeoglu, Y., Çetin, A. E.; Flame Detection in Video Using Hidden Markov Models, Proceedings of IEEE International Conference on Image Processing, 2005. p. 1230–1233.
- [111] Homg, W. B., Peng, J. W., Chen, C. Y.; A New Image–based Real–time Flame Detection Method Using Colour Analysis, Proceedings of IEEE Networking, Sensing and Control, ICNSC, 2005. p. 100–105.
- [112] Celik, T., Demirel, H., Ozkaramanli, H.; Automatic Fire Detection in Video Sequences, Proceedings of European Signal Processing Conference EUSIPCO, Florence, Italy, September, 2006.

- [113] Fazekas, S., Chetverikov, D.; Normal Versus Complete Flow in Dynamic Texture Recognition: A comparative study, Int. Workshop on Texture Analysis and Synthesis, 2005. p. 37–42.
- [114] Amiaz, T., Fazekas, S., Chetverikov, D., Kiryati, N.; Detecting Regions of Dynamic Texture, Int. Conf. on Scale Space and Variational Methods in Computer Vision, 2007.
- [115] Töreyn, U. B., Dedeoglu, Y., Çetin, A. E.; Wavelet Based Real –Time Smoke Detection in Video, 13th European Signal Processing Conference EUSIPCO, Antalya, Turkey, 2005.

## POPIS KRATICA I AKRONIMA

AC	–	Alternating Current
ASCOS	–	Analisis of Smoke Control System
AVI	–	Audio Video Interleave
CCD	–	Charge Coupled Device
CCTV	–	Closed Circuit Television
CFAST	–	Consolidated Model of Fire and Smoke Transport
CTL	–	Computation Tree Logic
DC	–	Direct Current
DCT	–	Discrete Cosine Transform
DTS	–	Digital Temperature Sensors
FDS	–	Fire Dynamics Simulator
FSSIM	–	Fire and Smoke Simulator
HMM	–	Hidden Markov Models
HSV	–	Hue Saturation and Value
IDCT	–	Inverse Discrete Cosine Transform
IMO	–	International Maritime Organization
IP	–	Internet Protocol
IR	–	Infrared
JPEG	–	Joint Photographic Experts Group
LHD	–	Linear Heat Detection
MPEG	–	Moving Picture Experts Group
NFPA	–	National Fire Protection Association
PC	–	Personal Computer
PLC	–	Programmable Logic Controller
RGB	–	Red Green Blue
SMV	–	Smokeview
SOLAS	–	Safety of Life at Sea

---

STM	–	Scanning Tunneling Microscope
UV	–	Ultraviolet
VCA	–	Video Content Analysis
VDR	–	Voyage Dana Recorder
VFD	–	Video Fire Detection
VFSD	–	Video Fire and Smoke Detection
VID	–	Video Image Detection
VISD	–	Video Image Smoke Detection



## POPIS OZNAKA I SIMBOLA

$\Delta m_f$	gubitak mase goriva (g)
$\mu$	intenzitet popravka
$\lambda$	intenzitet otkaza sredstva
$\frac{\delta N}{\delta d}$	broj raspodjele veličina funkcija ( $\text{cm}^{-3}\mu\text{m}^{-1}$ )
$Q_{total}$	ukupni prijenos topline na detektor (kW)
$Q_{cond}$	vidljivi prijenos topline (kW)
$Q_{conv}$	konvektivni prijenos topline (kW)
$Q_{rad}$	prijenos topline zračenjem (kW)
$q''$	toplina zračenja energije (u ovom slučaju, požar) ( $\text{W}/\text{m}^2$ )
$q''_{min}$	minimalna temperatura toplinskog toka potrebnog za paljenje ( $\text{kW}/\text{m}^2$ )
$q'''_{crit}$	kritična temperatura toplinskog toka potrebnog za paljenje ( $\text{kW}/\text{m}^2$ )
$q''_r$	vanjski tok topline ( $\text{kW}/\text{m}^2$ )
$\varepsilon$	emisija objekta (učinkovitost površinskog zračenja)
$\tau$	atmosfersko propuštanje
$\rho$	gustoća materijala ( $\text{kg}/\text{m}^3$ )
$f_p$	frekvencija preventivnog održavanja
$y_s$	frakcija lebdećih čestica (dim) u odnosu na masu gubitka goriva
$\sigma$	Stefan-Boltzmaonva konstanta materijala ( $56.7 \times 10^{-12} \text{ kW}/\text{m}^2\text{K}^4$ )
$A$	površina detekcije ( $\text{m}^2$ )
$A_i$	dimno područje u jedinici vremena
$A_o$	raspoloživost sustava u stvarnoj radnoj sredini
$A(t)$	raspoloživost sustava
$B$	vrijednost plave komponente
$b$	konstanta povezana s kpc ( $\text{sec}^{-1/2}$ )
$c$	specifični toplinski kapacitet u $\text{J}/\text{kg } ^\circ\text{C}$

---

$C(u)$ i $C(v)$	skup rezultata, koji se određuje prema vrijednosti koeficijenta $u$ i $v$
$D1$ i $D2$	granične vrijednosti donje i gornje brzine povećavanja dima
$d$	promjer čestica ( $\mu\text{m}$ )
$D_m$	masa optičke gustoće goriva ( $\text{m}^2/\text{g}$ )
$D_u$	optička gustoća po metru ( $\text{m}^{-1}$ )
FTPn	vremenski tok produkt
$F(u, v)$	koordinate DCT koeficijenata
$f(x, y)$	vrijednost piksela matrice u točki $(x, y)$
$G$	vrijednost zelene komponente
$h$	koeficijent konvektivnog prijenosa topline ( $\text{kW}/\text{m}^2\text{K}$ )
$hb$	ton boje
$H_c$	koeficijent prijenosa konvektivne topline ( $\text{kW}/^\circ\text{C}$ )
$H_d$	granična vrijednost broja zadovoljavanja uvjeta ( $D_1 < \overline{\Delta A_{di}} < D_2$ )
$h_{ig}$	koeficijent prijenosa topline kod paljenja ( $\text{W}/\text{m}^2\cdot\text{C}$ )
$i$	intenzitet svjetlosti
$i_o$	okvir slijeda slika
$i_k$	broj okvira
$k$	toplinska vodljivost ( $\text{W}/\text{m}^2 \cdot ^\circ\text{C}$ )
$k_s$	broj sličica između dviju odabranih ulaznih slika
$l$	udaljenost (m) gdje temperatura padne od $T1$ do $T2$ (u stupnjevima Kelvina)
$L_i$	donja granica zapaljivosti plina
$L_m$	donja granica zapaljivosti smjese
$L_o$	debljina materijala (m)
$m_f$	stopa gubitka mase goriva ( $\text{g}/\text{s}$ )
MDT	srednje ukupno vrijeme zastoja radi održavanja sustava
MPT	srednje vrijeme preventivnog održavanja
MTBF	srednje vrijeme između kvarova
MTBM	srednje vrijeme između održavanja
MTTR	srednje vrijeme popravka

$\bar{M}$	srednje vrijeme aktivnog održavanja
N	horizontale i vertikale (stupci i redovi)
N	indeks vremenskog protoka produkta koji je veći ili jednak 1
$P_i$	ukupan broj piksela dima u zahvaćenom prostoru
$P_i$	volumen plina
R	vrijednost crvene komponente
R(d)	funkcija odgovora detektora ( $\mu Vcm^3$ )
RT	vrijeme odziva ( $m \cdot sec$ ) <sup>1/2</sup>
R(t)	pouzdanost
S	električni signal detektora dima ( $\mu V$ )
s	komponenta zasićenja
SEP	suma opsega segmentiranih područja dima
STD	eksperimentalno određena granična vrijednost
STP	broj piksela koji su detektirani kao dim
T	temperatura u °K
t	vrijeme aktivacije detektora (s)
T <sub>A</sub>	srednje administrativno vrijeme zastoja zbog administrativnih razloga
T <sub>a</sub>	temperatura zraka okoline (°C)
t <sub>a</sub>	vrijeme paljenja (sek.)
T <sub>c</sub>	srednje vrijeme čekanja početka održavanja
T <sub>d</sub>	temperatura alarma (alarmna točka u °C)
T <sub>g</sub>	temperatura požarnih plinova (°C)
T <sub>i</sub>	početna temperatura od površine goriva (izvorni temperatura) (°C)
T <sub>ig</sub>	temperatura zapaljenja (°C)
t <sub>ig</sub>	vrijeme potrebno za paljenje (sek.)
T <sub>jet</sub>	stropna temperatura (°C)

---

TL	srednje logističko vrijeme čekanja na resurse održavanja
$t_m$	vrijeme do toplinske ravnoteže (sek.)
$T_o$	početna temperatura ( $^{\circ}\text{C}$ )
$T_p$	temperatura detektora ( $^{\circ}\text{C}$ )
TRP	povratni toplinski parametar ( $\text{kW} \cdot \text{sec}^{1/2}/\text{m}^2$ )
$T_s$	površinska temperatura ( $^{\circ}\text{C}$ ) za kruto gorivo
$T_{sa}$	temperatura paljenja ( $^{\circ}\text{C}$ )
$u_{jet}$	stropna brzina mlaza plamena (m/s)
V	volumetrični protok ( $\text{m}^3/\text{s}$ )
Vc	volumen raspršene mase ( $\text{m}^3$ )

## POPIS SLIKA

Naslov slike	Strana
1. Princip rada bimetalnog detektora	18
2. Prikaz današnjih fiksni toplinskih detektora na bazi bimetal	19
3. Prikaz stropnog mlaza plamena	20
4. Linijski temperaturni detektori	22
5. Termodiferencijalni temperaturni detektor	22
6. Elektropneumatski temperaturni detektor	23
7. Ionizirajući detektor dima	26
8. Električni krug ionizirajućeg detektora dima	26
9. Optički detektor dima	27
10. Princip rada optičkog detektora dima sa raspršenom svjetlošću	27
11. Princip rada optičkog detektora dima sa direktnom svjetlošću	28
12. Usporedbe standardnog fotoelektričnog detektora dima i laserskog detektora dima	29
13. Emisija energetskog spektra	30
14. Način smještaja UV detektora plamena	31
15. Prikaz stropne ugradnje UV detektora plamena	32
16. Kut gledanja UV detektora plamena tip Apollo	32
17. Vrste IR detektora plamena	33
18. Kut i visina prijema AC–IR 3Fq detektora plamena	34
19. Područje pokrivenosti i klasa (prag) osjetljivosti AC–IR 3Fq detektora plamena	34
20. Ručni javljači	35
21. Površina pokrivenosti detektora	36
22. Idealna površina nadziranja dimnih detektora i detektora temperature	37
23. Primjer zona detekcije s konvencionalnim petljama	41
24. Adresabilna petlja s adresiranim jedinicama detekcije	42
25. Vatrodojavnih sustava zasnovan na uporabi svjetlovodnog kabela	44

---

26.	Bežični vatrodojavni sustav	45
27.	Komponente vatrodojavnog sustava	47
28.	Funkcija intenziteta kvarova	49
29.	Pribor za testiranje detektora vatrodojavnog sustava	50
30.	Stablo kvarovima detekcije i alarma požara podijeljen u šest podsustava	53
31.	Stablo grešaka detektora	53
32.	Stablo grešaka u komponentama	53
33.	Stablo grešaka u komunikaciji	54
34.	Stablo grešaka pomoćnih upravljačkih podsustava	54
35.	Stablo grešaka napajanja	54
36.	Stablo lažnih alarma	54
37.	Osnovni uvjeti gorenja	58
38.	Izvori paljenja	63
39.	Krivulja različitih ponašanja požara	67
40.	Shematski prikaz tijeka požara	75
41.	Arhitektura među veza vatrodojavnih sustava i njihova integracija u brodski integrirani sustav	83
42.	Prikaz visoke redundancije po SOLAS propisima sigurnog povratka u luku	84
43.	Svjetlovodni detektor temperature na principu fazne razlike dva svjetlosna snopa	89
44.	Svjetlovodni detektor temperature pomoću deformacije vlakna	89
45.	Laserski detektor	90
46.	Integracija senzora detekcije požara s robotskim sustavom	91
47.	Spektar elektromagnetskih valova sa naglaskom na infracrveno područje	93
48.	Shematski prikaz općeg termografskog mjerenja	94
49.	Termovizija broorskog pomoćnog motora	95
50.	Termovizija elektro motora brodske pumpe	95
51.	Termovizija elektro sklopnika	96

52.	Tipična konfiguracija sustava vatrodaje pomoću termovizijskih kamera	97
53.	Podjela brodske strojarnice u 9 zona za CFAST model rasta požara	102
54.	Raspodjela modela višeslojne geometrijske strukture	103
55.	Raspodjela dima u višeslojnoj i jednoslojnoj strukturi	103
56.	RGB model prostora boja	104
57.	HSI prostor boja	106
58.	Algoritam detekcije dima na videu u svrhu sustava ranog alarmiranja	109
59.	Usporedba područja detekcije klasičnih detektora i video tehnologije upotrebom računalnog vida	110
60.	Koncept klasičnog modela algoritma požara, distribucije izlaznih signala i VID sustava	111
61.	Model detekcije dima temeljen na računalnom vidu u realnom vremenu upotrebom brodskih IP kamera	113
62.	Kompresija ulazne slike na 8 X 8 blokova	115
63.	Boje RGB modela koje se detektiraju kao dim	116
64.	Prikazivanje slike modelima boja pomoću programa MATLAB	117
65.	Usporedba pozadinske slike i područja interesa ROI	118
66.	Detektirani dim na prikazanoj slici	121
67.	Scenarij 1 – detekcija dima bez uključene ventilacije strojarnice	124
68.	Scenarij 2 – detekcija dima sa uključenom ventilacijom strojarnice	125
69.	Pozicije IP kamera za test video detekcije dima	126
70.	Videosustav nadzora ELRO DVR74S	127
71.	Videodetekcija dima pomoću 4 kamere u razmaku od 3 sekunde	128
72.	Videoslike od nastanka dima do alarma	129

## POPIS TABLICA

Broj tablice	Strana
1. Vrijeme odziva (RTI) za fiksne temperaturne detektore	20
2. Vrijeme odziva (RTI) za termodiferencijalne temperaturne detektore (9°C/min)	21
3. Vrijeme odziva (RTI) za detektore s autokompenzacijom	21
4. Odabir detektora plamena s obzirom na vrstu goriva i izvor lažnih alarma	30
5. Klasa (prag) osjetljivosti AC-IR 3Fq detektora plamena	33
6. Pravila postavljanja detektora temperature i dima	36
7. Frekvencija učestalosti požara izazvanih teškim i dizelskim gorivom	61
8. Frekvencija učestalosti požara uređaja u brodskoj strojarnici	62
9. Plamišta i temperature samozapaljenja s obzirom na vrstu zapaljive tekućine	71
10. Prvih deset fazi pravila za otkrivanje požarnih problema	85
11. Procjena temperature požara temeljem boje plamena	96
12. Popis autora i godina te tehnika upotrebe detekcije požara i dima	100
13. Vrijeme alarma optičkih detektora dima bez uključene ventilacije strojarnice	125
14. Vrijeme alarma optičkih detektora dima s uključenom ventilacijom strojarnice	125
15. Vrijeme detekcije dima test scenarij 1 i scenarij 2 i razlika u brzini detekcije	126
16. Orijentacija kamera za pojedinačni test	127
17. Vrijeme detekcije od nastanka dima do alarma	130
18. Vrijednosti vremena detekcije dima upotrebom IP kamera	131
19. Usporedba srednjih vremenskih vrijednosti detekcije dima uporabom optičkih detektora dima i detekcije dima zasnovanog na računalnom vidu	133
20. Cijene sustava i uređaja brodske strojarnice sagrađenih u Brodogradilištu Uljanik	134
21. Cijene brodskih vatrodojavnih sustava i CCTV sustava za tri tipa broda	135



## POPIS GRAFIKONA

Broj grafikona	Strana
1. Prikaz podrijetla i uzroka požara na brodovima	59
2. Uzroci požara u brodskim strojarnicama	60
3. Prikaz postotka gubitka s obzirom na jačinu požara	78
4. Postotak broja požara prema vrsti plovila	78
5. Postotak učestalosti uzroka požara strojarnice	78
6. Učestalost požara – grupirano po težini i razvrstano po starosti plovila	79
7. Broj žrtava – navedeno po vrsti plovila i razvrstano prema mjestu događaja	79
8. Predviđanje rasta tržišta nanotehnologije do 2010. godine	86
9. Učešće tržišta za nanotehnologiju u 2008. godini	87
10. Usporedba vremena alarma detekcije dima s (scenarij 1) i bez uključene ventilacije strojarnice (scenarij 2)	126
11. Vremena alarma detekcije dima upotrebom kamera (tri različita test)	131
12. Usporedba vremena aktiviranja optičkih detektora dima bez uključene ventilacije i videodetekcije dima upotrebom IP kamera	132
13. Usporedba vremena aktiviranja optičkih detektora dima s uključenom ventilacijom i videodetekcije dima upotrebom IP kamera	133
14. Vremena detekcije dima upotrebom optičkih detektora i VID tehnologije	134

## Životopis

Rođen sam 8. svibnja 1958. godine u Rijeci. Od druge godine života živim u Puli, gdje sam završio osnovnu i srednju tehničku školu. Na Pomorskom fakultetu u Rijeci, 2003. godine, diplomirao sam na dvogodišnjem stručnom studiju smjer – Brodska elektronika i komunikacije iz predmeta Računalno upravljanje brodskim sustavima i stekao naziv inženjer pomorskog prometa smjera pomorskih komunikacija i brodske elektronike. Razlikovnu godinu upisao sam 2008. godine, smjer Elektroničke i informatičke tehnologije u pomorstvu i stekao zvanje sveučilišni prvostupnik (baccalaureus) inženjer elektroničke i informatičke tehnologije. Godine 2010., također na Pomorskom fakultetu u Rijeci, upisao sam sveučilišni diplomski studij, smjer – Logistika i menadžment u pomorstvu i prometu. Diplomirao sam 2012. godine te stekao visoku stručnu spremu i zvanje magistar inženjer logistike i menadžmenta.

Od 1980. godine zaposlen sam u poduzeću *Uljanik* brodogradilište d.d., kao ispitivač brodske elektroopreme i uređaja. Godine 1989., raspoređen sam na radno mjesto višeg samostalnog ispitivača brodske elektroopreme i uređaja, dok 2012. godine prelazim na radno mjesto voditelja ispitivanja, a potom i rukovoditelja ureda za ispitivanje brodske automatike. Tijekom radnog vijeka uz rad na ispitivanju elektroopreme i uređaja mnogih renomiranih domaćih i svjetskih proizvođača brodske elektroopreme, sudjelovao sam u probnim vožnjama na preko 200 novogradnji različitih tipova u timu za ispitivanje sustava strojarnica, paluba, nadgrađa i komandnog mosta. Pored poznavanja MS Office programskog paketa, uz dodatno usavršavanje 2000. godine, stječem certifikat koji se odnosi na samostalno ispitivanje i puštanje u pogon vatrodojavnih sustava proizvođača *Scana Serviteknikk*. Iste godine, trening programom osposobljavanja, stječem certifikat osposobljenosti za rad na automatskim sustavima *Lyngsø Marine*. Također, 2008. godine, stječem certifikat koji mi omogućava ispitivanje, puštanje u pogon te samostalno programiranje alarmnog sustava vatrodojave tvrtke *Consilium*.

U akademskoj godini 2012./13., upisujem na Pomorskom fakultetu u Rijeci Poslijediplomski doktorski studij 'Pomorstvo', Modul: Elektronika i pomorske komunikacije (2. godina, prosjek ocjena: 5,0). Područje istraživanja na ovome studiju usko je orijentirano na brodske vatrodojavne sustave s naglaskom na primjenu novih elektroničkih i informatičkih

tehnologija i tehnika za identifikaciju dinamičkih procesa za optimizaciju kapaciteta broorskog vatrodojavnog sustava.

Godine 2014., odlukom Fakultetskog vijeća, Pomorskog fakulteta Sveučilišta u Rijeci, izabran sam u naslovno – suradničko zvanje asistent iz područja tehničkih znanosti, polje tehnologije prometa i transport, grane pomorski i riječni promet na Zavodu za elektrotehniku, automatiku i informatiku.

U svojstvu istraživača na projektu Ministarstva znanosti, obrazovanja i sporta pod nazivom *Informacijsko-komunikacijske tehnologije u inteligentnim pomorskim sustavima* broj 112-1121722-3314, voditelja prof. dr. sc. Vinka Tomasa, aktivno surađujem do 31. prosinca 2013. godine. Istraživanje je od 2014. godine nastavljeno uz potporu Sveučilišta u Rijeci za projekt pod naslovom: *Informacijsko-komunikacijske tehnologije u inteligentnim prometnim sustavima*.

Samostalno i u koautorstvu do sada sam objavio 7 znanstvenih i stručnih radova, tri u časopisima i četiri u zbornicima međunarodnih i domaćih konferencija.